

# Ordonnancement et réplication de données bioinformatiques dans un contexte de grille de calcul

ANTOINE VERNOIS

11 octobre 2006



*École normale supérieure de Lyon – LIP*



*Institut de Biologie des Protéines*

# Plan de l'expos

- 1 Motivations
  - Des applications bioinformatiques
- 2 Une approche statique
- 3 Passage en dynamique
- 4 Conclusions

## Grands projets de séquençage de génomes complets

homme, souris, animaux, végétaux, unicellulaires

## Croissance exponentielle de l'information biologique

- doublement de la taille des banques tous les 12 mois
- 1 ou 2 nouveaux génomes complets par mois
- plusieurs dizaines de Gos par mois

## Traitements informatiques

- de courtes durées
- en très grand nombre


# Des chiffres

Provenant de traces du serveur NPS@ de l'IBCP

<http://npsa-pbil.ibcp.fr/>

nombre de banques de données	23
nombre d'algorithmes	8
nombre de couples algorithme-banque de données	80
nombre de requêtes	88730
taille de la plus petite banque	1 MB
taille de la plus grande banque	12 GB

# La bioinformatique actuellement



# Les grilles de calculs




## Une grille

- mutualisation de ressources
  - ▶ calcul
  - ▶ stockage
- accès unifié et transparent

## Une solution possible

- pour le stockage
- pour les ressources de calcul
- pour l'accès à ces ressources

# La bioinformatique et les grilles



# L'idée simple

## On place toutes les banques sur tous les serveurs

- pas possible : trop de données
- beaucoup de gâchis d'espace
  - ▶ toutes les banques ne sont pas utilisées tout le temps
  - ▶ (embl.fas = 12GO, < 1% des requêtes)
- les mises à jour deviennent coûteuses

## Cache-Web ?

Similitude avec les pages web. Mais

à des échelles différentes

# L'idée simple

## On place toutes les banques sur tous les serveurs

- pas possible : trop de données
- beaucoup de gâchis d'espace
  - ▶ toutes les banques ne sont pas utilisées tout le temps
  - ▶ (embl.fas = 12GO, < 1% des requêtes)
- les mises à jour deviennent coûteuses

## Cache-Web ?

Similitude avec les pages web. Mais

- échelles différentes
- coûts de calcul

# L'idée simple

## On place toutes les banques sur tous les serveurs

- pas possible : trop de données
- beaucoup de gâchis d'espace
  - ▶ toutes les banques ne sont pas utilisées tout le temps
  - ▶ (embl.fas = 12GO, < 1% des requêtes)
- les mises à jour deviennent coûteuses

## Cache-Web ?

Similitude avec les pages web. **Mais**

- échelles différentes
- coûts de calcul

# L'idée simple

## On place toutes les banques sur tous les serveurs

- pas possible : trop de données
- beaucoup de gâchis d'espace
  - ▶ toutes les banques ne sont pas utilisées tout le temps
  - ▶ (embl.fas = 12GO, < 1% des requêtes)
- les mises à jour deviennent coûteuses

## Cache-Web ?

Similitude avec les pages web. Mais

- échelles différentes
- coûts de calcul

# L'idée simple

## On place toutes les banques sur tous les serveurs

- pas possible : trop de données
- beaucoup de gâchis d'espace
  - ▶ toutes les banques ne sont pas utilisées tout le temps
  - ▶ (embl.fas = 12GO, < 1% des requêtes)
- les mises à jour deviennent coûteuses

## Cache-Web ?

Similitude avec les pages web. Mais

- échelles différentes
- coûts de calcul

# Travaux précédents

## Service de réplication

- mécanismes pour localisation, stockage, réplication
  - ▶ souvent à la charge de l'utilisateur
- ne tient pas compte de tous les paramètres
  - ▶ capacité de stockage et calcul
  - ▶ utilisation des données
  - ▶ type d'opérations

## Réplication et ordonnancement

- Foster et al.
  - décision locale de réplication
  - ordonnancement externe sur les sites ayant les données
- Chakrabarti et al. : IRS
  - ordonnancement « on-line »
  - placement amélioré itérativement en fonction de l'utilisation

# Travaux précédents

## Service de réplication

- mécanismes pour localisation, stockage, réplication
  - ▶ souvent à la charge de l'utilisateur
- ne tient pas compte de tous les paramètres
  - ▶ capacité de stockage et calcul
  - ▶ utilisation des données
  - ▶ type d'opérations

## Réplication et ordonnancement

- Foster et al.
  - ▶ décision locale de réplication
  - ▶ ordonnancement externe sur les sites ayant les données
- Chakrabarti et al. : IRS
  - ▶ ordonnancement « on-line »
  - ▶ placement amélioré itérativement en fonction de l'utilisation

# Travaux précédents

## Service de réplication

- mécanismes pour localisation, stockage, réplication
  - ▶ souvent à la charge de l'utilisateur
- ne tient pas compte de tous les paramètres
  - ▶ capacité de stockage et calcul
  - ▶ utilisation des données
  - ▶ type d'opérations

## Réplication et ordonnancement

- Foster et al.
  - ▶ décision locale de réplication
  - ▶ ordonnancement externe sur les sites ayant les données
- Chakrabarti et al. : IRS
  - ▶ ordonnancement « on-line »
  - ▶ placement amélioré itérativement en fonction de l'utilisation

# Analyse des traces

## À partir des logs de NPS@ :

- des utilisations différentes entre les requêtes
  - ▶ BLAST sur Swiss-Prot : 77% des requêtes
- globalement, l'utilisation reste la même

On peut utiliser l'analyse des requêtes précédentes comme point de départ.

# Analyse des traces

## À partir des logs de NPS@ :

- des utilisations différentes entre les requêtes
  - ▶ BLAST sur Swiss-Prot : 77% des requêtes
- globalement, l'utilisation reste la même

On peut utiliser l'analyse des requêtes précédentes comme point de départ.

# Analyse des traces

## À partir des logs de NPS@ :

- des utilisations différentes entre les requêtes
  - ▶ BLAST sur Swiss-Prot : 77% des requêtes
- globalement, l'utilisation reste la même

On peut utiliser l'analyse des requêtes précédentes comme point de départ.


# Sommaire

- 1 Motivations
  - Des applications bioinformatiques
- 2 Une approche statique
- 3 Passage en dynamique
- 4 Conclusions

# Plan de l'expos


- 1 Motivations
- 2 Une approche statique
  - Paramètres
  - Contraintes
  - Simulations
  - Prototype
- 3 Passage en dynamique
- 4 Conclusions

# Intégration dans une plate-forme



- Calcul du placement et de l'ordonnement
- Placement des données sur les serveurs
- Ordonnement des requêtes à leur arrivée

# Intégration dans une plate-forme



- Calcul du placement et de l'ordonnancement
- Placement des données sur les serveurs
- Ordonnancement des requêtes à leur arrivée

# Modélisation - 1/2

## La plate-forme

- $n$  serveurs de calcul  $P_i$ 
  - ▶ espace de stockage :  $m_i$
  - ▶ puissance de calcul :  $w_i$

## Les données bioinformatiques

- $m$  banques de données  $d_j$  de taille :  $size_j$
- $p$  algorithmes  $a_k$  :
  - ▶ coût linéaire :  $\alpha_k.size_j + c_k$
- des requêtes  $R(k, j)$ 
  - ▶ fréquence d'utilisation du couple :  $f(k, j)$

# Modélisation - 1/2

## La plate-forme

- $n$  serveurs de calcul  $P_i$ 
  - ▶ espace de stockage :  $m_i$
  - ▶ puissance de calcul :  $w_i$

## Les données bioinformatiques

- $m$  banques de données  $d_j$  de taille :  $size_j$
- $p$  algorithmes  $a_k$  :
  - ▶ coût linéaire :  $\alpha_k.size_j + c_k$
- des requêtes  $R(k, j)$ 
  - ▶ fréquence d'utilisation du couple :  $f(k, j)$

# Modélisation - 1/2

## La plate-forme

- $n$  serveurs de calcul  $P_i$ 
  - ▶ espace de stockage :  $m_i$
  - ▶ puissance de calcul :  $w_i$

## Les données bioinformatiques

- $m$  banques de données  $d_j$  de taille :  $size_j$
- $p$  algorithmes  $a_k$  :
  - ▶ coût linéaire :  $\alpha_k \cdot size_j + c_k$
- des requêtes  $R(k, j)$ 
  - ▶ fréquence d'utilisation du couple :  $f(k, j)$

# Modélisation - 2/2

## Les inconnues

- $\delta_i^j$  : placement de la donnée  $d_j$  sur  $P_i$
- $n_i(k, j)$  : nombre de requêtes de type  $R(k, j)$  effectuées sur  $P_i$
- $TP$  : débit de la plate-forme en terme de requêtes

# Les contraintes 1/2

## Les contraintes sur le placement

- toutes les données stockées au moins une fois

$$\forall i \in [1, m], \sum_{j=1}^n \delta_i^j \geq 1$$

- un serveur ne peut pas stocker plus que son espace

$$\forall i \in [1, m], \sum_{j=1}^n \delta_i^j \cdot \text{size}_j \leq m_i$$

## Les contraintes sur le calcul

# Les contraintes 1/2

## Les contraintes sur le placement

- toutes les données stockées au moins une fois

$$\forall i \in [1, m], \sum_{j=1}^n \delta_i^j \geq 1$$

- un serveur ne peut pas stocker plus que son espace

$$\forall i \in [1, m], \sum_{j=1}^n \delta_i^j \cdot \text{size}_j \leq m_i$$

## Les contraintes sur le calcul

- un serveur ne peut pas exécuter plus que sa puissance

$$\forall i \in [1, m], \sum_{j=1}^n \delta_i^j \cdot \text{cpu}_j \leq \text{cpu}_i$$

# Les contraintes 1/2

## Les contraintes sur le placement

- toutes les données stockées au moins une fois

$$\forall i \in [1, m], \sum_{j=1}^n \delta_i^j \geq 1$$

- un serveur ne peut pas stocker plus que son espace

$$\forall i \in [1, m], \sum_{j=1}^n \delta_i^j \cdot \text{size}_j \leq m_i$$

## Les contraintes sur le calcul

- un serveur ne peut pas exécuter plus que sa puissance

$$\forall i \in [1, m], \sum_{k=1}^n \sum_{j=1}^n n_i(k, j) (\alpha_k \cdot \text{size}_j + c_k) \leq w_i$$

# Les contraintes 1/2

## Les contraintes sur le placement

- toutes les données stockées au moins une fois

$$\forall i \in [1, m], \sum_{j=1}^n \delta_i^j \geq 1$$

- un serveur ne peut pas stocker plus que son espace

$$\forall i \in [1, m], \sum_{j=1}^n \delta_i^j \cdot \text{size}_j \leq m_i$$

## Les contraintes sur le calcul

- un serveur ne peut pas exécuter plus que sa puissance

$$\forall i \in [1, m], \sum_{k=1}^p \sum_{j=1}^n n_i(k, j) (\alpha_k * \text{size}_j + c_k) \leq w_i$$

# Les contraintes 1/2

## Les contraintes sur le placement

- toutes les données stockées au moins une fois

$$\forall i \in [1, m], \sum_{j=1}^n \delta_i^j \geq 1$$

- un serveur ne peut pas stocker plus que son espace

$$\forall i \in [1, m], \sum_{j=1}^n \delta_i^j \cdot \text{size}_j \leq m_i$$

## Les contraintes sur le calcul

- un serveur ne peut pas exécuter plus que sa puissance

$$\forall i \in [1, m], \sum_{k=1}^p \sum_{j=1}^n n_i(k, j) (\alpha_k * \text{size}_j + c_k) \leq w_i$$

# Les contraintes 2/2

## Les contraintes conjointes

- on exécute une requête que si la donnée est présente

$$\forall i \in [1, m], \forall j \in [1, n], \forall k \in [1, p], n_i(k, j) \leq v_{k,j} \cdot \delta_i^j \cdot \frac{w_i}{\alpha_k \cdot \text{size}_j + c_k}$$

- le nombre de jobs exécutés respecte les fréquences

$$\forall i \in [1, m], \forall j \in [1, n], \sum_{i=1}^m n_i(k, j) = f_{k,j} \cdot TP$$

## Objectif

Maximiser le débit de la plate-forme

# Les contraintes 2/2

## Les contraintes conjointes

- on exécute une requête que si la donnée est présente

$$\forall i \in [1, m], \forall j \in [1, n], \forall k \in [1, p], n_i(k, j) \leq v_{k,j} \cdot \delta_i^j \cdot \frac{w_i}{\alpha_k \cdot \text{size}_j + c_k}$$

- le nombre de jobs exécutés respecte les fréquences

$$\forall i \in [1, m], \forall j \in [1, n], \sum_{i=1}^m n_i(k, j) = f_{k,j} \cdot TP$$

## Objectif

Maximiser le débit de la plate-forme

# Les contraintes 2/2

## Les contraintes conjointes

- on exécute une requête que si la donnée est présente

$$\forall i \in [1, m], \forall j \in [1, n], \forall k \in [1, p], n_i(k, j) \leq v_{k,j} \cdot \delta_i^j \cdot \frac{w_i}{\alpha_k \cdot \text{size}_j + c_k}$$

- le nombre de jobs exécutés respecte les fréquences

$$\forall i \in [1, m], \forall j \in [1, n], \sum_{i=1}^m n_i(k, j) = f_{k,j} \cdot TP$$

## Objectif

Maximiser le débit de la plate-forme

# Les contraintes 2/2

## Les contraintes conjointes

- on exécute une requête que si la donnée est présente

$$\forall i \in [1, m], \forall j \in [1, n], \forall k \in [1, p], n_i(k, j) \leq v_{k,j} \cdot \delta_i^j \cdot \frac{w_i}{\alpha_k \cdot \text{size}_j + c_k}$$

- le nombre de jobs exécutés respecte les fréquences

$$\forall i \in [1, m], \forall j \in [1, n], \sum_{i=1}^m n_i(k, j) = f_{k,j} \cdot TP$$

## Objectif

Maximiser le débit de la plate-forme

# Le programme linéaire

## Formulation du programme linéaire

MAXIMISER  $TP$ ,

SOUS LES CONTRAINTES

$$\left\{ \begin{array}{ll} (1) \sum_{j=1}^n \delta_i^j \geq 1 & 1 \leq i \leq m \\ (2) \sum_{j=1}^n \delta_i^j \cdot size_j \leq m_i & 1 \leq i \leq m \\ (3) \sum_{k=1}^p \sum_{j=1}^n n_i(k, j) (\alpha_k \cdot size_j + c_k) \leq w_i & 1 \leq i \leq m \\ (4) n_i(k, j) \leq v_{k,j} \cdot \delta_i^j \cdot \frac{w_i}{\alpha_k \cdot size_j + c_k} & 1 \leq i \leq m, 1 \leq j \leq n, 1 \leq k \leq p \\ (5) \sum_{i=1}^m n_i(k, j) = f_{k,j} \cdot TP & 1 \leq i \leq m, 1 \leq j \leq n \end{array} \right.$$


# Approximer la solution

## Complétude

Le problème d'ordonnancement et de placement conjoint est NP-complet.

## Programme linéaire mixte

- approximation itérative entière pour  $\delta_i^j$



# Simulation

## Utilisation de OptorSim

- simulateur dédié à la gestion des données sur les grilles
- développé dans le cadre de EDG

## Largement modifié pour répondre à nos besoins

- hétérogénéité des serveurs de calculs
- CE type gestionnaire de batch
- intégration des temps de calculs
- mécanismes nécessaires à notre solution

# Tests

## Plate-forme simulée

- générée par Tiers
- 10 plate-formes


## Requêtes

- basées sur des requêtes réelles
- 40000 requêtes

## Comparaison

- SRA : notre algorithme
- MCT : placement de SRA + ordonnancement MCT
- greedy : un placement glouton et ordonnancement MCT

## Exemple de plate-forme



# Tests

## Plate-forme simulée

- générée par Tiers
- 10 plate-formes


## Requêtes

- basées sur des requêtes réelles
- 40000 requêtes

## Comparaison

- SRA : notre algorithme
- MCT : placement de SRA + ordonnancement MCT
- greedy : un placement glouton et ordonnancement MCT

## Exemple de plate-forme



# Tests


## Plate-forme simulée

- générée par Tiers
- 10 plate-formes

## Requêtes

- basées sur des requêtes réelles
- 40000 requêtes

## Exemple de plate-forme



## Comparaison

- SRA : notre algorithme
- MCT : placement de SRA + ordonnancement MCT
- greedy : un placement glouton et ordonnancement MCT

# Tests

## Plate-forme simulée

- générée par Tiers
- 10 plate-formes


## Requêtes

- basées sur des requêtes réelles
- 40000 requêtes


## Comparaison

- SRA : notre algorithme
- MCT : placement de SRA + ordonnancement MCT
- greedy : un placement glouton et ordonnancement MCT


## Exemple de plate-forme



# Temps d'exécution : fonction du débit réseau



# Temps d'exécution : fonction de l'espace de stockage



# Implémentation d'un prototype

## Plate-forme logicielle

- DIET : Distributed Interactive Engineering Toolbox
  - gestionnaire de requête
  - LIP - ENS Lyon
- DTM : Data Tree Manager
  - gestionnaire de données pour la grille
  - Université de Besançon
- LogService + VizDIET
  - monitoring et visualisation

## Plate-forme matérielle

- Grid'5000
  - 11 serveurs
  - 5 sites

# Implémentation d'un prototype

## Plate-forme logicielle

- DIET : Distributed Interactive Engineering Toolbox
  - ▶ gestionnaire de requête
  - ▶ LIP - ENS Lyon
- DTM : Data Tree Manager
  - ▶ gestionnaire de données pour la grille
  - ▶ Université de Besançon
- LogService + VizDIET
  - ▶ monitoring et visualisation

## Plate-forme matérielle

- Grid'5000
  - ▶ 11 serveurs
  - ▶ 5 sites

# Implémentation d'un prototype

## Plate-forme logicielle

- DIET : Distributed Interactive Engineering Toolbox
  - ▶ gestionnaire de requête
  - ▶ LIP - ENS Lyon
- DTM : Data Tree Manager
  - ▶ gestionnaire de données pour la grille
  - ▶ Université de Besançon
- LogService + VizDIET
  - ▶ monitoring et visualisation

## Plate-forme matérielle

- Grid'5000
  - ▶ 11 serveurs
  - ▶ 5 sites

# Implémentation d'un prototype

## Plate-forme logicielle

- DIET : Distributed Interactive Engineering Toolbox
  - ▶ gestionnaire de requête
  - ▶ LIP - ENS Lyon
- DTM : Data Tree Manager
  - ▶ gestionnaire de données pour la grille
  - ▶ Université de Besançon
- LogService + VizDIET
  - ▶ monitoring et visualisation

## Plate-forme matérielle

- Grid'5000
  - ▶ 11 serveurs
  - ▶ 5 sites

# Implémentation d'un prototype

## Plate-forme logicielle

- DIET : Distributed Interactive Engineering Toolbox
  - ▶ gestionnaire de requête
  - ▶ LIP - ENS Lyon
- DTM : Data Tree Manager
  - ▶ gestionnaire de données pour la grille
  - ▶ Université de Besançon
- LogService + VizDIET
  - ▶ monitoring et visualisation


## Plate-forme matérielle

- Grid'5000
  - ▶ 11 serveurs
  - ▶ 5 sites




## Diagramme de Gantt

## Greedy




## SRA




	glouton	SRA
temps de calcul	47953 s	41618 s

## Diagramme de Gantt

## Greedy



## SRA



	glouton	SRA
temps de calcul	47953 s	41618 s

# Plan de l'expos

- 1 Motivations
- 2 Une approche statique
- 3 Passage en dynamique
  - Introduction
  - Heuristiques
  - Simulations et résultats
- 4 Conclusions

# Limites de la solution statique

- si les schémas ne sont pas suivis
- utilisation ponctuelle d'une banque


# Limites de la solution statique

- si les schémas ne sont pas suivis
- utilisation ponctuelle d'une banque

Faire une version dynamique


# Détecter et décider

## Architecture fonctionnelle




# Détecter et décider

## Architecture fonctionnelle




# Détecter et décider

## Architecture fonctionnelle



# Détecter et décider

## Architecture fonctionnelle



# Algorithme général

- 1: **Tant que** il y a des requêtes à traiter :
- 2:   Regarder la charge des serveurs
- 3:   **Si** il y a des serveurs en surcharge **Alors**
- 4:     Choisir le serveur  $P_{surcharge}$  le plus surchargé
- 5:     Déterminer la donnée  $D_{charge}$  cause de la surcharge
- 6:     Choisir un serveur  $P_{sous-charge}$  en sous-charge
- 7:     **Si** il y a assez de place pour répliquer  $D_{charge}$  sur  $P_{sous-charge}$  **Alors**
- 8:       Répliquer
- 9:     **Sinon**
- 10:       **Tant que** il n'y a pas assez de place sur  $P_{sous-charge}$  pour  $D_{charge}$  :
- 11:         Choisir une donnée à supprimer sur  $D_{charge}$
- 12:         **Si** il n'y a toujours pas assez de place **Alors**
- 13:         Restaurer les données supprimées
- 14:         Choisir un autre serveur pour  $P_{sous-charge}$  et recommencer à partir de 7
- 15:         **Si** des données ont été répliquées ou supprimées **Alors**
- 16:         Mettre à jour l'ordonnancement
- 17:         Resoumettre les requêtes concernées
- 18:     Attendre un temps *delai*

# Algorithme général

- 1: **Tant que** il y a des requêtes à traiter :
- 2:   Regarder la charge des serveurs
- 3:   **Si** il y a des serveurs en surcharge **Alors**
- 4:     Choisir le serveur  $P_{surcharge}$  le plus surchargé
- 5:     Déterminer la donnée  $D_{charge}$  cause de la surcharge
- 6:     Choisir un serveur  $P_{sous-charge}$  en sous-charge
- 7:     **Si** il y a assez de place pour répliquer  $D_{charge}$  sur  $P_{sous-charge}$  **Alors**
- 8:       Répliquer
- 9:     **Sinon**
- 10:       **Tant que** il n'y a pas assez de place sur  $P_{sous-charge}$  pour  $D_{charge}$  :
- 11:         Choisir une donnée à supprimer sur  $D_{charge}$
- 12:         **Si** il n'y a toujours pas assez de place **Alors**
- 13:         Restaurer les données supprimées
- 14:         Choisir un autre serveur pour  $P_{sous-charge}$  et recommencer à partir de 7
- 15:         **Si** des données ont été répliquées ou supprimées **Alors**
- 16:         Mettre à jour l'ordonnancement
- 17:         Resoumettre les requêtes concernées
- 18:     Attendre un temps *delai*

# Algorithme général

- 1: **Tant que** il y a des requêtes à traiter :
- 2:   Regarder la charge des serveurs
- 3:   **Si** il y a des serveurs en surcharge **Alors**
- 4:     Choisir le serveur  $P_{surcharge}$  le plus surchargé
- 5:     Déterminer la donnée  $D_{charge}$  cause de la surcharge
- 6:     Choisir un serveur  $P_{sous-charge}$  en sous-charge
- 7:     **Si** il y a assez de place pour répliquer  $D_{charge}$  sur  $P_{sous-charge}$  **Alors**
- 8:       Répliquer
- 9:     **Sinon**
- 10:       **Tant que** il n'y a pas assez de place sur  $P_{sous-charge}$  pour  $D_{charge}$  :
- 11:         Choisir une donnée à supprimer sur  $D_{charge}$
- 12:         **Si** il n'y a toujours pas assez de place **Alors**
- 13:         Restaurer les données supprimées
- 14:         Choisir un autre serveur pour  $P_{sous-charge}$  et recommencer à partir de 7
- 15:         **Si** des données ont été répliquées ou supprimées **Alors**
- 16:         Mettre à jour l'ordonnancement
- 17:         Resoumettre les requêtes concernées
- 18:     Attendre un temps *delai*

# Algorithme général

- 1: **Tant que** il y a des requêtes à traiter :
- 2:   Regarder la charge des serveurs
- 3:   **Si** il y a des serveurs en surcharge **Alors**
- 4:     Choisir le serveur  $P_{surcharge}$  le plus surchargé
- 5:     Déterminer la donnée  $D_{charge}$  cause de la surcharge
- 6:     Choisir un serveur  $P_{sous-charge}$  en sous-charge
- 7:     **Si** il y a assez de place pour répliquer  $D_{charge}$  sur  $P_{sous-charge}$  **Alors**
- 8:       Répliquer
- 9:     **Sinon**
- 10:       **Tant que** il n'y a pas assez de place sur  $P_{sous-charge}$  pour  $D_{charge}$  :
- 11:         Choisir une donnée à supprimer sur  $D_{charge}$
- 12:         **Si** il n'y a toujours pas assez de place **Alors**
- 13:         Restaurer les données supprimées
- 14:         Choisir un autre serveur pour  $P_{sous-charge}$  et recommencer à partir de 7
- 15:         **Si** des données ont été répliquées ou supprimées **Alors**
- 16:         Mettre à jour l'ordonnancement
- 17:         Resoumettre les requêtes concernées
- 18:     Attendre un temps *delai*

# Algorithme général

- 1: **Tant que** il y a des requêtes à traiter :
- 2:   Regarder la charge des serveurs
- 3:   **Si** il y a des serveurs en surcharge **Alors**
- 4:     Choisir le serveur  $P_{surcharge}$  le plus surchargé
- 5:     Déterminer la donnée  $D_{charge}$  cause de la surcharge
- 6:     Choisir un serveur  $P_{sous-charge}$  en sous-charge
- 7:     **Si** il y a assez de place pour répliquer  $D_{charge}$  sur  $P_{sous-charge}$  **Alors**
- 8:       Répliquer
- 9:     **Sinon**
- 10:       **Tant que** il n'y a pas assez de place sur  $P_{sous-charge}$  pour  $D_{charge}$  :
- 11:         Choisir une donnée à supprimer sur  $D_{charge}$
- 12:       **Si** il n'y a toujours pas assez de place **Alors**
- 13:         Restaurer les données supprimées
- 14:         Choisir un autre serveur pour  $P_{sous-charge}$  et recommencer à partir de 7
- 15:       **Si** des données ont été répliquées ou supprimées **Alors**
- 16:         Mettre à jour l'ordonnancement
- 17:         Resoumettre les requêtes concernées
- 18:     Attendre un temps *delai*

# Algorithme général

- 1: **Tant que** il y a des requêtes à traiter :
- 2:   Regarder la charge des serveurs
- 3:   **Si** il y a des serveurs en surcharge **Alors**
- 4:     Choisir le serveur  $P_{surcharge}$  le plus surchargé
- 5:     Déterminer la donnée  $D_{charge}$  cause de la surcharge
- 6:     Choisir un serveur  $P_{sous-charge}$  en sous-charge
- 7:     **Si** il y a assez de place pour répliquer  $D_{charge}$  sur  $P_{sous-charge}$  **Alors**
- 8:       Répliquer
- 9:     **Sinon**
- 10:       **Tant que** il n'y a pas assez de place sur  $P_{sous-charge}$  pour  $D_{charge}$  :
- 11:         Choisir une donnée à supprimer sur  $D_{charge}$
- 12:         **Si** il n'y a toujours pas assez de place **Alors**
- 13:         Restaurer les données supprimées
- 14:         Choisir un autre serveur pour  $P_{sous-charge}$  et recommencer à partir de 7
- 15:         **Si** des données ont été répliquées ou supprimées **Alors**
- 16:         **Mettre à jour l'ordonnancement**
- 17:         Resoumettre les requêtes concernées
- 18:     Attendre un temps *delai*

# Heuristiques - 1/3

## Choix du serveur en surcharge

- MaxCompServ
  - ▶ plus grand temps de calcul en attente
- MaxOverMedianServ
  - ▶ plus grand écart en volume de calcul entre temps de calcul et temps de calcul moyen

## Cause de la surcharge

- MaxCompData
  - ▶ donnée représentant le plus grand volume de calcul
- MaxDiffData
  - ▶ donnée dont la différence entre utilisation prévue et réelle est la plus grande

# Heuristiques - 1/3

## Choix du serveur en surcharge

- MaxCompServ
  - ▶ plus grand temps de calcul en attente
- MaxOverMedianServ
  - ▶ plus grand écart en volume de calcul entre temps de calcul et temps de calcul moyen

## Cause de la surcharge

- MaxCompData
  - ▶ donnée représentant le plus grand volume de calcul
- MaxDiffData
  - ▶ donnée dont la différence entre utilisation prévue et réelle est la plus grande

# Heuristiques - 2/3

## Choix du serveur cible

- MinTimeServ
  - ▶ plus court temps de calcul en attente
- MaxUnderMedianServ
  - ▶ plus grand écart en volume de calcul entre temps de calcul et temps de calcul moyen

## Suppression des données

- MinCompData
  - ▶ donnée représentant le plus petit volume de calcul
- LessUsedData
  - ▶ donnée dont la fréquence d'utilisation est la plus faible

# Heuristiques - 2/3

## Choix du serveur cible

- MinTimeServ
  - ▶ plus court temps de calcul en attente
- MaxUnderMedianServ
  - ▶ plus grand écart en volume de calcul entre temps de calcul et temps de calcul moyen

## Suppression des données

- MinCompData
  - ▶ donnée représentant le plus petit volume de calcul
- LessUsedData
  - ▶ donnée dont la fréquence d'utilisation est la plus faible

# Heuristiques - 3/3

## Réordonnancer

- LPSched
  - ▶ recalcul du programme linéaire
- EqShareSched
  - ▶ partage égal entre le nouveau et l'ancien serveur
- MedianCompSched
  - ▶ on redistribue les calculs pour que l'un des 2 serveurs revienne a la moyenne

# Environnement

## Simulateur

version modifiée d'Optorsim

## Plate-formes

générées par Tiers

## Requêtes

Ensemble de 40000 requêtes :

- généré à partir des jeux de requêtes réelles
- différent de la distribution originale
- 3 types

• tous : tous les types changent

• mixte : juste les 10-15 requêtes

# Environnement

## Simulateur

version modifiée d'Optorsim

## Plate-formes

générées par Tiers

## Requêtes

Ensemble de 40000 requêtes :

- généré à partir des jeux de requêtes réelles
- différent de la distribution originale
- 3 types
  - tous : tous les types changent
  - min10 : juste les 10 - fréquentes
  - max10 : juste les 10 + fréquentes

# Environnement

## Simulateur

version modifiée d'Optorsim

## Plate-formes

générées par Tiers

## Requêtes

Ensemble de 40000 requêtes :

- généré à partir des jeux de requêtes réelles
- différent de la distribution originale
- 3 types
  - ▶ **tous** : tous les types changent
  - ▶ min10 : juste les 10 - fréquentes
  - ▶ max10 : juste les 10 + fréquentes

# Environnement

## Simulateur

version modifiée d'Optorsim

## Plate-formes

générées par Tiers

## Requêtes

Ensemble de 40000 requêtes :

- généré à partir des jeux de requêtes réelles
- différent de la distribution originale
- 3 types
  - ▶ tous : tous les types changent
  - ▶ **min10** : juste les 10 - fréquentes
  - ▶ max10 : juste les 10 + fréquentes

# Environnement

## Simulateur

version modifiée d'Optorsim

## Plate-formes

générées par Tiers

## Requêtes

Ensemble de 40000 requêtes :


- généré à partir des jeux de requêtes réelles
- différent de la distribution originale
- 3 types
  - ▶ tous : tous les types changent
  - ▶ min10 : juste les 10 - fréquentes
  - ▶ **max10** : juste les 10 + fréquentes

# Heuristiques testées


## 13 combinaisons

	serveur surchargé	données de surcharge	serveur sous-chargé	données à supprimer	ordonnancement
0	aucun	aucun	aucun	aucun	aucun
1	MaxTimeServ	MaxCompData	MinTimeServ	aucun	EqShareSched
2	MaxTimeServ	MaxCompData	MinTimeServ	MinCompData	LPSched
3	MaxTimeServ	MaxCompData	MinTimeServ	MinCompData	EqShareSched
4	MaxTimeServ	MaxCompData	MinTimeServ	MinCompData	MedianCompSched
5	MaxTimeServ	MaxDiff	MinTimeServ	LessUsed	LPSched
6	MaxTimeServ	MaxDiff	MinTimeServ	LessUsed	EqShare
7	MaxTimeServ	MaxDiff	MinTimeServ	LessUsed	MedianCompSched
8	MaxOverMedianServ	MaxCompData	MinOverMedianServ	MinCompData	LPSched
9	MaxOverMedianServ	MaxCompData	MinOverMedianServ	MinCompData	EqShare
10	MaxOverMedianServ	MaxCompData	MinOverMedianServ	MinCompData	MedianCompSched
11	MaxOverMedianServ	MaxDiff	MinOverMedianServ	LessUsed	LPSched
12	MaxOverMedianServ	MaxDiff	MinOverMedianServ	LessUsed	EqShare
13	MaxOverMedianServ	MaxDiff	MinOverMedianServ	LessUsed	MedianCompSched


# Temps d'exécution : tous différents




# Temps d'exécution : tous différents



## Temps d'exécution : min10



## Temps d'exécution : max10



# Heuristiques testées

## 13 combinaisons

	serveur surchargé	données de surcharge	serveur sous-chargé	données à supprimer	ordonnancement
0	aucun	aucun	aucun	aucun	aucun
1	MaxTimeServ	MaxCompData	MinTimeServ	aucun	EqShareSched
2	MaxTimeServ	MaxCompData	MinTimeServ	MinCompData	LPSched
3	MaxTimeServ	MaxCompData	MinTimeServ	MinCompData	EqShareSched
4	MaxTimeServ	MaxCompData	MinTimeServ	MinCompData	MedianCompSched
5	MaxTimeServ	MaxDiff	MinTimeServ	LessUsed	LPSched
6	MaxTimeServ	MaxDiff	MinTimeServ	LessUsed	EqShare
7	MaxTimeServ	MaxDiff	MinTimeServ	LessUsed	MedianCompSched
8	MaxOverMedianServ	MaxCompData	MinOverMedianServ	MinCompData	LPSched
9	MaxOverMedianServ	MaxCompData	MinOverMedianServ	MinCompData	EqShareSched
10	MaxOverMedianServ	MaxCompData	MinOverMedianServ	MinCompData	MedianCompSched
11	MaxOverMedianServ	MaxDiff	MinOverMedianServ	LessUsed	LPSched
12	MaxOverMedianServ	MaxDiff	MinOverMedianServ	LessUsed	EqShare
13	MaxOverMedianServ	MaxDiff	MinOverMedianServ	LessUsed	MedianCompSched

# Heuristiques testées

## 13 combinaisons

	serveur surchargé	données de surcharge	serveur sous-chargé	données à supprimer	ordonnancement
0	aucun	aucun	aucun	aucun	aucun
1	MaxTimeServ	MaxCompData	MinTimeServ	aucun	EqShareSched
2	MaxTimeServ	MaxCompData	MinTimeServ	MinCompData	LPSched
3	MaxTimeServ	MaxCompData	MinTimeServ	MinCompData	EqShareSched
4	MaxTimeServ	MaxCompData	MinTimeServ	MinCompData	MedianCompSched
5	MaxTimeServ	MaxDiff	MinTimeServ	LessUsed	LPSched
6	MaxTimeServ	MaxDiff	MinTimeServ	LessUsed	EqShare
7	MaxTimeServ	MaxDiff	MinTimeServ	LessUsed	MedianCompSched
8	MaxOverMedianServ	MaxCompData	MinOverMedianServ	MinCompData	LPSched
9	MaxOverMedianServ	MaxCompData	MinOverMedianServ	MinCompData	EqShareSched
10	MaxOverMedianServ	MaxCompData	MinOverMedianServ	MinCompData	MedianCompSched
11	MaxOverMedianServ	MaxDiff	MinOverMedianServ	LessUsed	LPSched
12	MaxOverMedianServ	MaxDiff	MinOverMedianServ	LessUsed	EqShare
13	MaxOverMedianServ	MaxDiff	MinOverMedianServ	LessUsed	MedianCompSched

# Heuristiques testées

## 13 combinaisons

	serveur surchargé	données de surcharge	serveur sous-chargé	données à supprimer	ordonnancement
0	aucun	aucun	aucun	aucun	aucun
1	MaxTimeServ	MaxCompData	MinTimeServ	aucun	EqShareSched
2	MaxTimeServ	MaxCompData	MinTimeServ	MinCompData	LPSched
3	MaxTimeServ	MaxCompData	MinTimeServ	MinCompData	EqShareSched
4	MaxTimeServ	MaxCompData	MinTimeServ	MinCompData	MedianCompSched
5	MaxTimeServ	MaxDiff	MinTimeServ	LessUsed	LPSched
6	MaxTimeServ	MaxDiff	MinTimeServ	LessUsed	EqShare
7	MaxTimeServ	MaxDiff	MinTimeServ	LessUsed	MedianCompSched
8	MaxOverMedianServ	MaxCompData	MinOverMedianServ	MinCompData	LPSched
9	MaxOverMedianServ	MaxCompData	MinOverMedianServ	MinCompData	EqShareSched
10	MaxOverMedianServ	MaxCompData	MinOverMedianServ	MinCompData	MedianCompSched
11	MaxOverMedianServ	MaxDiff	MinOverMedianServ	LessUsed	LPSched
12	MaxOverMedianServ	MaxDiff	MinOverMedianServ	LessUsed	EqShare
13	MaxOverMedianServ	MaxDiff	MinOverMedianServ	LessUsed	MedianCompSched

# Plan de l'expos

- 1 Motivations
- 2 Une approche statique
- 3 Passage en dynamique
- 4 Conclusions**
  - Contributions
  - La suite...

# Algorithmes d'ordonnancement et de réplication

## Statique

- modélisation en régime permanent
- validé par simulation et expérimentalement
  - ▶ simulateur basé sur Optorsim
  - ▶ prototype dans DIET/DTM
- bonne optimisation pour
  - ▶ réseau lent
  - ▶ espace de stockage limité

## Dynamique

- nombreuses heuristiques
- bons résultats pour certaines
- stabilise le temps d'exécution

# Futur proche

## Implémentation de DynSRA

- DIET/DTM
- CORI pour la remontée d'informations

## Prise en compte des coûts de transfert

- thèse de Gaël Lemahec (CC IN2P3 / LIP)

# À long terme

## Placement et ordonnancement conjoint

- domaine récent
- problème NP-complet
  - ▶ le problème du placement à lui seul est NP-complet
- accroissement de la taille des données
  - ▶ bioinformatique, physique, océanographie, ...
- d'autres modèles d'applications

# À long terme

## Placement et ordonnancement conjoint

- domaine récent
- problème NP-complet
  - ▶ le problème du placement à lui seul est NP-complet
- accroissement de la taille des données
  - ▶ bioinformatique, physique, océanographie, ...
- d'autres modèles d'applications

Le sujet reste très ouvert