

Algorithmes itératifs et plates-formes distribuées hétérogènes

Frédéric Vivien

INRIA - LIP

27 avril 2004

Plan de l'exposé

- 1 Présentation du problème
- 2 Réseau complet homogène
- 3 Réseau complet hétérogène
- 4 Réseau hétérogène quelconque
- 5 Plates-formes non dédiées

Plan de l'exposé

- 1 Présentation du problème
- 2 Réseau complet homogène
- 3 Réseau complet hétérogène
- 4 Réseau hétérogène quelconque
- 5 Plates-formes non dédiées

Plan de l'exposé

- 1 Présentation du problème
- 2 Réseau complet homogène
- 3 Réseau complet hétérogène
- 4 Réseau hétérogène quelconque
- 5 Plates-formes non dédiées

Plan de l'exposé

- 1 Présentation du problème
- 2 Réseau complet homogène
- 3 Réseau complet hétérogène
- 4 Réseau hétérogène quelconque
- 5 Plates-formes non dédiées

Plan de l'exposé

- 1 Présentation du problème
- 2 Réseau complet homogène
- 3 Réseau complet hétérogène
- 4 Réseau hétérogène quelconque
- 5 Plates-formes non dédiées

Plan de l'exposé

- 1 Présentation du problème
- 2 Réseau complet homogène
- 3 Réseau complet hétérogène
- 4 Réseau hétérogène quelconque
- 5 Plates-formes non dédiées

Le contexte: plates-formes distribuées hétérogènes

Évolution des plates-formes considérées

- Abandon des ordinateurs parallèles (coût...)
- Souhait d'utiliser toute la puissance disponible

Modification des problématiques

- Hétérogénéité des processeurs
- Hétérogénéité des liens de communications
- Topologie réseau (plus ou moins) inconnue
- Machines et réseau non dédiés

Plates-formes distribuées hétérogènes

(networks-of-workstations, clusters, grille, etc.)

Applications considérées: algorithmes itératifs

- Un ensemble de données (typiquement une matrice)
- Schéma de l'algorithme:
 - 1 Chaque processeur effectue un calcul sur sa part des données
 - 2 Chaque processeur échange la « frontière » de son ensemble de données avec ses processeurs voisins
 - 3 On recommence à l'étape 1

Question: comment exécuter efficacement un tel algorithme sur une telle plate-forme ?

Applications considérées: algorithmes itératifs

- Un ensemble de données (typiquement une matrice)
- Schéma de l'algorithme:
 - 1 Chaque processeur effectue un calcul sur sa part des données
 - 2 Chaque processeur échange la « frontière » de son ensemble de données avec ses processeurs voisins
 - 3 On recommence à l'étape 1

Question: comment exécuter efficacement un tel algorithme sur une telle plate-forme ?

Applications considérées: algorithmes itératifs

- Un ensemble de données (typiquement une matrice)
- Schéma de l'algorithme:
 - 1 Chaque processeur effectue un calcul sur sa part des données
 - 2 Chaque processeur échange la « frontière » de son ensemble de données avec ses processeurs voisins
 - 3 On recommence à l'étape 1

Question: comment exécuter efficacement un tel algorithme sur une telle plate-forme ?

Applications considérées: algorithmes itératifs

- Un ensemble de données (typiquement une matrice)
- Schéma de l'algorithme:
 - 1 Chaque processeur effectue un calcul sur sa part des données
 - 2 Chaque processeur échange la « frontière » de son ensemble de données avec ses processeurs voisins
 - 3 On recommence à l'étape 1

Question: comment exécuter efficacement un tel algorithme sur une telle plate-forme ?

Applications considérées: algorithmes itératifs

- Un ensemble de données (typiquement une matrice)
- Schéma de l'algorithme:
 - 1 Chaque processeur effectue un calcul sur sa part des données
 - 2 Chaque processeur échange la « frontière » de son ensemble de données avec ses processeurs voisins
 - 3 On recommence à l'étape 1

Question: comment exécuter efficacement un tel algorithme sur une telle plate-forme ?

Applications considérées: algorithmes itératifs

- Un ensemble de données (typiquement une matrice)
- Schéma de l'algorithme:
 - 1 Chaque processeur effectue un calcul sur sa part des données
 - 2 Chaque processeur échange la « frontière » de son ensemble de données avec ses processeurs voisins
 - 3 On recommence à l'étape 1


Question: comment exécuter efficacement un tel algorithme sur une telle plate-forme ?

Les questions

- Quels processeurs doivent participer au calcul ?
- Quel fraction des données doit-on leur allouer ?
- Comment doit-on découper l'ensemble des données ?

Simplification préalable: découpage par bande


- Données: un tableau 2D
- Découpage: par bandes verticales



- Conséquences:
 - ① Détermination simple des frontières et des voisins
 - ② Volume de données à échanger entre voisins constants: $\mathcal{O}(1)$
 - ③ Pas trop compliqué...

Simplification préalable: découpage par bande


- Données: un tableau 2D
- Découpage: par bandes verticales



- Conséquences:
 - 1 Détermination simple des frontières et des voisins
 - 2 Volume de données à échanger entre voisins constants: \mathcal{D}_i
 - 3 Pas trop compliqué...

Simplification préalable: découpage par bande


- Données: un tableau 2D
- Découpage: par bandes verticales



- Conséquences:
 - 1 Détermination simple des frontières et des voisins
 - 2 Volume de données à échanger entre voisins constants: D_c
 - 3 Pas trop compliqué...

Simplification préalable: découpage par bande


- Données: un tableau 2D
- Découpage: par bandes verticales



- Conséquences:
 - 1 Détermination simple des frontières et des voisins
 - 2 Volume de données à échanger entre voisins constants: D_c
 - 3 Pas trop compliqué...

Simplification préalable: découpage par bande


- Données: un tableau 2D
- Découpage: par bandes verticales



- Conséquences:
 - 1 Détermination simple des frontières et des voisins
 - 2 Volume de données à échanger entre voisins constants: D_c
 - 3 Pas trop compliqué...

Simplification préalable: découpage par bande

- Données: un tableau 2D
- Découpage: par bandes verticales



- Conséquences:
 - 1 Détermination simple des frontières et des voisins
 - 2 Volume de données à échanger entre voisins constants: D_c
 - 3 Pas trop compliqué...

Notations

- Processeurs: P_1, \dots, P_p
- Le processeur P_i exécute une tâche unitaire en un temps w_i
- Quantité total de travail D_w ; part de P_i : $\alpha_i \cdot D_w$
($\alpha_i \geq 0, \sum_j \alpha_j = 1$)
- Communications: modèle 1-port (envoi à un voisin à la fois; réception d'un voisin à la fois; envoi et réception simultanés)
- Coût d'un envoi unitaire de P_i à P_j : $c_{i,j}$
- Coût d'un envoi de P_i à son successeur dans l'anneau: $D_c \cdot c_{i, \text{succ}(i)}$

Notations

- Processeurs: P_1, \dots, P_p
- Le processeur P_i exécute une tâche unitaire en un temps w_i
- Quantité total de travail D_w ; part de P_i : $\alpha_i \cdot D_w$
($\alpha_i \geq 0, \sum_j \alpha_j = 1$)
- Communications: modèle 1-port (envoi à un voisin à la fois; réception d'un voisin à la fois; envoi et réception simultanés)
- Coût d'un envoi unitaire de P_i à P_j : $c_{i,j}$
- Coût d'un envoi de P_i à son successeur dans l'anneau: $D_c \cdot c_{i, \text{succ}(i)}$

Notations

- Processeurs: P_1, \dots, P_p
- Le processeur P_i exécute une tâche unitaire en un temps w_i
- Quantité total de travail D_w ; part de P_i : $\alpha_i \cdot D_w$
($\alpha_i \geq 0, \sum_j \alpha_j = 1$)
- Communications: modèle 1-port (envoi à un voisin à la fois; réception d'un voisin à la fois; envoi et réception simultanés)
- Coût d'un envoi unitaire de P_i à P_j : $c_{i,j}$
- Coût d'un envoi de P_i à son successeur dans l'anneau: $D_c \cdot c_{i, \text{succ}(i)}$

Notations

- Processeurs: P_1, \dots, P_p
- Le processeur P_i exécute une tâche unitaire en un temps w_i
- Quantité total de travail D_w ; part de P_i : $\alpha_i \cdot D_w$
($\alpha_i \geq 0, \sum_j \alpha_j = 1$)
- Communications: modèle 1-port (envoi à un voisin à la fois; réception d'un voisin à la fois; envoi et réception simultanés)
- Coût d'un envoi unitaire de P_i à P_j : $c_{i,j}$
- Coût d'un envoi de P_i à son successeur dans l'anneau: $D_c \cdot c_{i, \text{succ}(i)}$

Notations

- Processeurs: P_1, \dots, P_p
- Le processeur P_i exécute une tâche unitaire en un temps w_i
- Quantité total de travail D_w ; part de P_i : $\alpha_i \cdot D_w$
($\alpha_i \geq 0, \sum_j \alpha_j = 1$)
- Communications: modèle 1-port (envoi à un voisin à la fois; réception d'un voisin à la fois; envoi et réception simultanés)
- Coût d'un envoi unitaire de P_i à P_j : $c_{i,j}$
- Coût d'un envoi de P_i à son successeur dans l'anneau: $D_c \cdot c_{i, \text{succ}(i)}$

Notations

- Processeurs: P_1, \dots, P_p
- Le processeur P_i exécute une tâche unitaire en un temps w_i
- Quantité total de travail D_w ; part de P_i : $\alpha_i \cdot D_w$
($\alpha_i \geq 0, \sum_j \alpha_j = 1$)
- Communications: modèle 1-port (envoi à un voisin à la fois; réception d'un voisin à la fois; envoi et réception simultanés)
- Coût d'un envoi unitaire de P_i à P_j : $c_{i,j}$
- Coût d'un envoi de P_i à son successeur dans l'anneau: $D_c \cdot c_{i, \text{succ}(i)}$

Objectif

- 1 Sélectionner q processeurs parmi p
- 2 Les ordonner en un anneau
- 3 Leur répartir les données

Afin de minimiser:

$$\max_{1 \leq i \leq p} \mathbb{I}\{i\} [\alpha_i \cdot D_w \cdot w_i + D_c \cdot (c_{i, \text{pred}(i)} + c_{i, \text{succ}(i)})]$$

Où $\mathbb{I}\{i\}[x] = x$ si P_i participe au calcul et 0 sinon

Objectif

- 1 Sélectionner q processeurs parmi p
- 2 Les ordonner en un anneau
- 3 Leur répartir les données

Afin de minimiser:

$$\max_{1 \leq i \leq p} \mathbb{I}\{i\} [\alpha_i \cdot D_w \cdot w_i + D_c \cdot (c_{i, \text{pred}(i)} + c_{i, \text{succ}(i)})]$$

Où $\mathbb{I}\{i\}[x] = x$ si P_i participe au calcul et 0 sinon

Objectif

- 1 Sélectionner q processeurs parmi p
- 2 Les ordonner en un anneau
- 3 Leur répartir les données

Afin de minimiser:

$$\max_{1 \leq i \leq p} \mathbb{I}\{i\} [\alpha_i \cdot D_w \cdot w_i + D_c \cdot (c_{i, \text{pred}(i)} + c_{i, \text{succ}(i)})]$$

Où $\mathbb{I}\{i\}[x] = x$ si P_i participe au calcul et 0 sinon

Objectif

- 1 Sélectionner q processeurs parmi p
- 2 Les ordonner en un anneau
- 3 Leur répartir les données

Afin de minimiser:

$$\max_{1 \leq i \leq p} \mathbb{I}\{i\} [\alpha_i \cdot D_w \cdot w_i + D_c \cdot (c_{i, \text{pred}(i)} + c_{i, \text{succ}(i)})]$$


Où $\mathbb{I}\{i\}[x] = x$ si P_i participe au calcul et 0 sinon

Plan de l'exposé

- 1 Présentation du problème
- 2 Réseau complet homogène**
- 3 Réseau complet hétérogène
- 4 Réseau hétérogène quelconque
- 5 Plates-formes non dédiées

Hypothèses particulières

- 1 Il existe un lien de communication entre chaque paire de processeurs
- 2 Tous les liens ont même capacité de communication
($\exists c, \forall i, j \ c_{i,j} = c$)



Conséquences

- Soit le processeur le plus rapide fait tout le travail, soit tous les processeurs participent
- Si tous les processeurs participent, ils finissent tous leur part de calcul en même temps
 $\alpha_i \cdot D_w$ rationnels ???
($\exists r_i : \alpha_i \cdot D_w \cdot w_i = r_i$, d'où $1 = \sum_i \frac{r_i}{D_w \cdot w_i}$)
- Temps pour la solution optimale:

$$T_{\text{step}} = \min \left\{ D_w \cdot w_{\min}, D_w \cdot \frac{1}{\sum_i \frac{1}{w_i}} + 2 \cdot D_c \cdot c \right\}$$

Conséquences

- Soit le processeur le plus rapide fait tout le travail, soit tous les processeurs participent
- Si tous les processeurs participent, ils finissent tous leur part de calcul en même temps $\alpha_i \cdot D_w$ rationnels ???
($\exists \tau, \alpha_i \cdot D_w \cdot w_i = \tau$, d'où $1 = \sum_i \frac{\tau}{D_w \cdot w_i}$)
- Temps pour la solution optimale:

$$T_{\text{step}} = \min \left\{ D_w \cdot w_{\min}, D_w \cdot \frac{1}{\sum_i \frac{1}{w_i}} + 2 \cdot D_c \cdot c \right\}$$

Conséquences

- Soit le processeur le plus rapide fait tout le travail, soit tous les processeurs participent
- Si tous les processeurs participent, ils finissent tous leur part de calcul en même temps $\alpha_i \cdot D_w$ rationnels ???
($\exists \tau, \alpha_i \cdot D_w \cdot w_i = \tau$, d'où $1 = \sum_i \frac{\tau}{D_w \cdot w_i}$)
- Temps pour la solution optimale:

$$T_{\text{step}} = \min \left\{ D_w \cdot w_{\min}, D_w \cdot \frac{1}{\sum_i \frac{1}{w_i}} + 2 \cdot D_c \cdot c \right\}$$

Conséquences

- Soit le processeur le plus rapide fait tout le travail, soit tous les processeurs participent
- Si tous les processeurs participent, ils finissent tous leur part de calcul en même temps $\alpha_i \cdot D_w$ rationnels ???
($\exists \tau, \alpha_i \cdot D_w \cdot w_i = \tau$, d'où $1 = \sum_i \frac{\tau}{D_w \cdot w_i}$)
- Temps pour la solution optimale:

$$T_{\text{step}} = \min \left\{ D_w \cdot w_{\min}, D_w \cdot \frac{1}{\sum_i \frac{1}{w_i}} + 2 \cdot D_c \cdot c \right\}$$

Conséquences

- Soit le processeur le plus rapide fait tout le travail, soit tous les processeurs participent
- Si tous les processeurs participent, ils finissent tous leur part de calcul en même temps $\alpha_i \cdot D_w$ rationnels ???
($\exists \tau, \alpha_i \cdot D_w \cdot w_i = \tau$, d'où $1 = \sum_i \frac{\tau}{D_w \cdot w_i}$)
- Temps pour la solution optimale:


$$T_{\text{step}} = \min \left\{ D_w \cdot w_{\min}, D_w \cdot \frac{1}{\sum_i \frac{1}{w_i}} + 2 \cdot D_c \cdot c \right\}$$

Plan de l'exposé


- 1 Présentation du problème
- 2 Réseau complet homogène
- 3 Réseau complet hétérogène**
- 4 Réseau hétérogène quelconque
- 5 Plates-formes non dédiées

Hypothèse particulière

- 1 Il existe un lien de communication entre chaque paire de processeurs



Tous les processeurs participent: étude (1)



Tous les processeurs finissent en même temps

Tous les processeurs participent: étude (2)

- Ils finissent tous en même temps:

$$T_{\text{step}} = \alpha_i \cdot D_w \cdot w_i + D_c \cdot (c_{i,\text{succ}(i)} + c_{i,\text{pred}(i)})$$

- $\sum_{i=1}^p \alpha_i = 1 \Rightarrow \sum_{i=1}^p \frac{T_{\text{step}} - D_c \cdot (c_{i,\text{succ}(i)} + c_{i,\text{pred}(i)})}{D_w \cdot w_i} = 1$. D'où

$$\frac{T_{\text{step}}}{D_w \cdot w_{\text{cumul}}} = 1 + \frac{D_c}{D_w} \sum_{i=1}^p \frac{c_{i,\text{succ}(i)} + c_{i,\text{pred}(i)}}{w_i}$$

$$\text{où } w_{\text{cumul}} = \frac{1}{\sum_i \frac{1}{w_i}}$$

Tous les processeurs participent: étude (2)

- Ils finissent tous en même temps:

$$T_{\text{step}} = \alpha_i \cdot D_w \cdot w_i + D_c \cdot (c_{i,\text{succ}(i)} + c_{i,\text{pred}(i)})$$

- $\sum_{i=1}^p \alpha_i = 1 \Rightarrow \sum_{i=1}^p \frac{T_{\text{step}} - D_c \cdot (c_{i,\text{succ}(i)} + c_{i,\text{pred}(i)})}{D_w \cdot w_i} = 1$. D'où

$$\frac{T_{\text{step}}}{D_w \cdot w_{\text{cumul}}} = 1 + \frac{D_c}{D_w} \sum_{i=1}^p \frac{c_{i,\text{succ}(i)} + c_{i,\text{pred}(i)}}{w_i}$$

$$\text{où } w_{\text{cumul}} = \frac{1}{\sum_i \frac{1}{w_i}}$$

Tous les processeurs participent: interprétation

$$\frac{T_{\text{step}}}{D_w \cdot w_{\text{cumul}}} = 1 + \frac{D_c}{D_w} \sum_{i=1}^p \frac{c_{i,\text{succ}(i)} + c_{i,\text{pred}(i)}}{w_i}$$

T_{step} est minimal quand $\sum_{i=1}^p \frac{c_{i,\text{succ}(i)} + c_{i,\text{pred}(i)}}{w_i}$ est minimal

Recherche d'un cycle hamiltonien de poids minimal dans un graphe où l'arête de P_i à P_j est de poids $d_{i,j} = \frac{c_{i,j}}{w_i} + \frac{c_{j,i}}{w_j}$

Problème NP-complet

Tous les processeurs participent: interprétation

$$\frac{T_{\text{step}}}{D_w \cdot w_{\text{cumul}}} = 1 + \frac{D_c}{D_w} \sum_{i=1}^p \frac{c_{i,\text{succ}(i)} + c_{i,\text{pred}(i)}}{w_i}$$

T_{step} est minimal quand $\sum_{i=1}^p \frac{c_{i,\text{succ}(i)} + c_{i,\text{pred}(i)}}{w_i}$ est minimal

Recherche d'un cycle hamiltonien de poids minimal dans un graphe où l'arête de P_i à P_j est de poids $d_{i,j} = \frac{c_{i,j}}{w_i} + \frac{c_{j,i}}{w_j}$

Problème NP-complet

Tous les processeurs participent: interprétation

$$\frac{T_{\text{step}}}{D_w \cdot w_{\text{cumul}}} = 1 + \frac{D_c}{D_w} \sum_{i=1}^p \frac{c_{i,\text{succ}(i)} + c_{i,\text{pred}(i)}}{w_i}$$

T_{step} est minimal quand $\sum_{i=1}^p \frac{c_{i,\text{succ}(i)} + c_{i,\text{pred}(i)}}{w_i}$ est minimal

Recherche d'un cycle hamiltonien de poids minimal dans un graphe où l'arête de P_i à P_j est de poids $d_{i,j} = \frac{c_{i,j}}{w_i} + \frac{c_{j,i}}{w_j}$

Problème NP-complet

Tous les processeurs participent: interprétation

$$\frac{T_{\text{step}}}{D_w \cdot w_{\text{cumul}}} = 1 + \frac{D_c}{D_w} \sum_{i=1}^p \frac{c_{i,\text{succ}(i)} + c_{i,\text{pred}(i)}}{w_i}$$

T_{step} est minimal quand $\sum_{i=1}^p \frac{c_{i,\text{succ}(i)} + c_{i,\text{pred}(i)}}{w_i}$ est minimal

Recherche d'un cycle hamiltonien de poids minimal dans un graphe où l'arête de P_i à P_j est de poids $d_{i,j} = \frac{c_{i,j}}{w_i} + \frac{c_{j,i}}{w_j}$

Problème NP-complet

Tous les processeurs participent: programmation linéaire

$$\text{MINIMISER } \sum_{i=1}^p \sum_{j=1}^p d_{i,j} \cdot x_{i,j},$$

SATISFAISANT LES (IN)ÉQUATIONS

$$\left\{ \begin{array}{ll} (1) \sum_{j=1}^p x_{i,j} = 1 & 1 \leq i \leq p \\ (2) \sum_{i=1}^p x_{i,j} = 1 & 1 \leq j \leq p \\ (3) x_{i,j} \in \{0, 1\} & 1 \leq i, j \leq p \\ (4) u_i - u_j + p \cdot x_{i,j} \leq p - 1 & 2 \leq i, j \leq p, i \neq j \\ (5) u_i \text{ integer}, u_i \geq 0 & 2 \leq i \leq p \end{array} \right.$$

$x_{i,j} = 1$ si et seulement si l'arête de P_i à P_j est utilisée

Cas général: programmation linéaire

Meilleur anneau de q processeurs

MINIMISER T SATISFAISANTS LES (IN)ÉQUATIONS

$$\left\{ \begin{array}{ll} (1) & x_{i,j} \in \{0, 1\} \quad 1 \leq i, j \leq p \\ (2) & \sum_{i=1}^p x_{i,j} \leq 1 \quad 1 \leq j \leq p \\ (3) & \sum_{i=1}^p \sum_{j=1}^p x_{i,j} = q \\ (4) & \sum_{i=1}^p x_{i,j} = \sum_{i=1}^p x_{j,i} \quad 1 \leq j \leq p \\ (5) & \sum_{i=1}^p \alpha_i = 1 \\ (6) & \alpha_i \leq \sum_{j=1}^p x_{i,j} \quad 1 \leq i \leq p \\ (7) & \alpha_i \cdot w_i + \frac{D_c}{D_w} \sum_{j=1}^p (x_{i,j} c_{i,j} + x_{j,i} c_{j,i}) \leq T \quad 1 \leq i \leq p \\ (8) & \sum_{i=1}^p y_i = 1 \\ (9) & -p \cdot y_i - p \cdot y_j + u_i - u_j + q \cdot x_{i,j} \leq q - 1 \quad 1 \leq i, j \leq p, i \neq j \\ (10) & y_i \in \{0, 1\} \quad 1 \leq i \leq p \\ (11) & u_i \text{ integer}, u_i \geq 0 \quad 1 \leq i \leq p \end{array} \right.$$

La programmation linéaire

- Problèmes en rationnels: résolution en temps polynomial (en la taille du problème).
- Problèmes en entier: résolution en temps exponentiel dans le pire cas.
- Pas de relaxation en rationnels possible...

La programmation linéaire

- Problèmes en rationnels: résolution en temps polynomial (en la taille du problème).
- Problèmes en entier: résolution en temps exponentiel dans le pire cas.
- Pas de relaxation en rationnels possible...

La programmation linéaire

- Problèmes en rationnels: résolution en temps polynomial (en la taille du problème).
- Problèmes en entier: résolution en temps exponentiel dans le pire cas.
- Pas de relaxation en rationnels possible...

Et en pratique ?

Tous les processeurs participent. On utilise une heuristique de résolution du problème de voyageur de commerce (e.g. Lin-Kernighan)
Pas de garanties, mais en pratique les résultats sont excellents.

Cas général.

- ➊ Recherche exhaustive: faisable jusqu'à une douzaine de processeurs...
- ➋ Heuristique gloutonne: initialement on prend la meilleure paire de processeurs ; pour un anneau donné on essaye d'insérer n'importe quel processeur non utilisé entre chaque paire de voisins de l'anneau...

Et en pratique ?

Tous les processeurs participent. On utilise une heuristique de résolution du problème de voyageur de commerce (e.g. Lin-Kernighan)
Pas de garanties, mais en pratique les résultats sont excellents.

Cas général.

- 1 Recherche exhaustive: faisable jusqu'à une douzaine de processeurs...
- 2 Heuristique gloutonne: initialement on prend la meilleure paire de processeurs ; pour un anneau donné on essaye d'insérer n'importe quel processeur non utilisé entre chaque paire de voisins de l'anneau...

Et en pratique ?

Tous les processeurs participent. On utilise une heuristique de résolution du problème de voyageur de commerce (e.g. Lin-Kernighan)
Pas de garanties, mais en pratique les résultats sont excellents.

Cas général.

- 1 Recherche exhaustive: faisable jusqu'à une douzaine de processeurs...
- 2 Heuristique gloutonne: initialement on prend la meilleure paire de processeurs ; pour un anneau donné on essaye d'insérer n'importe quel processeur non utilisé entre chaque paire de voisins de l'anneau...

Et en pratique ?

Tous les processeurs participent. On utilise une heuristique de résolution du problème de voyageur de commerce (e.g. Lin-Kernighan)
Pas de garanties, mais en pratique les résultats sont excellents.

Cas général.

- 1 Recherche exhaustive: faisable jusqu'à une douzaine de processeurs...
- 2 Heuristique gloutonne: initialement on prend la meilleure paire de processeurs ; pour un anneau donné on essaye d'insérer n'importe quel processeur non utilisé entre chaque paire de voisins de l'anneau...

Et en pratique ?

Tous les processeurs participent. On utilise une heuristique de résolution du problème de voyageur de commerce (e.g. Lin-Kernighan)
Pas de garanties, mais en pratique les résultats sont excellents.


Cas général.

- 1 Recherche exhaustive: faisable jusqu'à une douzaine de processeurs...
- 2 Heuristique gloutonne: initialement on prend la meilleure paire de processeurs ; pour un anneau donné on essaye d'insérer n'importe quel processeur non utilisé entre chaque paire de voisins de l'anneau...

Plan de l'exposé

- 1 Présentation du problème
- 2 Réseau complet homogène
- 3 Réseau complet hétérogène
- 4 Réseau hétérogène quelconque**
- 5 Plates-formes non dédiées

Nouvelle difficulté: partage de liens de communications



Nouvelles notations

- Un ensemble de liens de communications: e_1, \dots, e_n
- Bande passante de e_m : b_{e_m}
- Il y a un chemin \mathcal{S}_i de P_i à $P_{\text{succ}(i)}$ dans le réseau
 - \mathcal{S}_i utilise une partie $s_{i,m}$ de la bande passante b_{e_m} du lien e_m
 - P_i a besoin d'un temps $\tau_{i,m} = \frac{D_i}{b_{e_m} - s_{i,m}}$ pour envoyer à $P_{\text{succ}(i)}$ successivement un message de taille D_i
 - Contraintes sur la bande passante de e_m :
$$\sum_{i \in \mathcal{S}_P} s_{i,m} \leq b_{e_m}$$
- De même il y a un chemin \mathcal{P}_i de P_i à $P_{\text{pred}(i)}$ dans le réseau
 - qui utilise une partie $p_{i,m}$ de la bande passante b_{e_m} du lien e_m

Nouvelles notations

- Un ensemble de liens de communications: e_1, \dots, e_n
- Bande passante de e_m : b_{e_m}
- Il y a un chemin \mathcal{S}_i de P_i à $P_{\text{succ}(i)}$ dans le réseau
 - \mathcal{S}_i utilise une partie $s_{i,m}$ de la bande passante b_{e_m} du lien e_m
 - P_i a besoin d'un temps $D_c \frac{1}{\min_{e_m \in \mathcal{S}_i} s_{i,m}}$ pour envoyer à son successeur un message de taille D_c
 - Contraintes sur la bande passante de e_m : $\sum_{i \in \mathcal{S}_i} s_{i,m} \leq b_{e_m}$
- De même il y a un chemin \mathcal{P}_i de P_i à $P_{\text{pred}(i)}$ dans le réseau qui utilise une partie $p_{i,m}$ de la bande passante b_{e_m} du lien e_m

Nouvelles notations

- Un ensemble de liens de communications: e_1, \dots, e_n
- Bande passante de e_m : b_{e_m}
- Il y a un chemin \mathcal{S}_i de P_i à $P_{\text{succ}(i)}$ dans le réseau
 \mathcal{S}_i utilise une partie $s_{i,m}$ de la bande passante b_{e_m} du lien e_m
 P_i a besoin d'un temps $D_c \cdot \frac{1}{\min_{e_m \in \mathcal{S}_i} s_{i,m}}$ pour envoyer à son successeur un message de taille D_c
Contraintes sur la bande passante de e_m : $\sum_{1 \leq i \leq p} s_{i,m} \leq b_{e_m}$
- De même il y a un chemin \mathcal{P}_i de P_i à $P_{\text{pred}(i)}$ dans le réseau qui utilise une partie $p_{i,m}$ de la bande passante b_{e_m} du lien e_m

Nouvelles notations

- Un ensemble de liens de communications: e_1, \dots, e_n
- Bande passante de e_m : b_{e_m}
- Il y a un chemin \mathcal{S}_i de P_i à $P_{\text{succ}(i)}$ dans le réseau
 \mathcal{S}_i utilise une partie $s_{i,m}$ de la bande passante b_{e_m} du lien e_m
 P_i a besoin d'un temps $D_c \cdot \frac{1}{\min_{e_m \in \mathcal{S}_i} s_{i,m}}$ pour envoyer à son successeur un message de taille D_c
Contraintes sur la bande passante de e_m : $\sum_{1 \leq i \leq p} s_{i,m} \leq b_{e_m}$
- De même il y a un chemin \mathcal{P}_i de P_i à $P_{\text{pred}(i)}$ dans le réseau qui utilise une partie $p_{i,m}$ de la bande passante b_{e_m} du lien e_m

Nouvelles notations

- Un ensemble de liens de communications: e_1, \dots, e_n
- Bande passante de e_m : b_{e_m}
- Il y a un chemin \mathcal{S}_i de P_i à $P_{\text{succ}(i)}$ dans le réseau
 \mathcal{S}_i utilise une partie $s_{i,m}$ de la bande passante b_{e_m} du lien e_m
 P_i a besoin d'un temps $D_c \cdot \frac{1}{\min_{e_m \in \mathcal{S}_i} s_{i,m}}$ pour envoyer à son successeur un message de taille D_c
Contraintes sur la bande passante de e_m : $\sum_{1 \leq i \leq p} s_{i,m} \leq b_{e_m}$
- De même il y a un chemin \mathcal{P}_i de P_i à $P_{\text{pred}(i)}$ dans le réseau, qui utilise une partie $p_{i,m}$ de la bande passante b_{e_m} du lien e_m


Nouvelles notations

- Un ensemble de liens de communications: e_1, \dots, e_n
- Bande passante de e_m : b_{e_m}
- Il y a un chemin \mathcal{S}_i de P_i à $P_{\text{succ}(i)}$ dans le réseau
 \mathcal{S}_i utilise une partie $s_{i,m}$ de la bande passante b_{e_m} du lien e_m
 P_i a besoin d'un temps $D_c \cdot \frac{1}{\min_{e_m \in \mathcal{S}_i} s_{i,m}}$ pour envoyer à son
successeur un message de taille D_c
Contraintes sur la bande passante de e_m :
$$\sum_{1 \leq i \leq p} s_{i,m} \leq b_{e_m}$$
- De même il y a un chemin \mathcal{P}_i de P_i à $P_{\text{pred}(i)}$ dans le réseau,
qui utilise une partie $p_{i,m}$ de la bande passante b_{e_m} du lien e_m

Nouvelles notations


- Un ensemble de liens de communications: e_1, \dots, e_n
- Bande passante de e_m : b_{e_m}
- Il y a un chemin \mathcal{S}_i de P_i à $P_{\text{succ}(i)}$ dans le réseau
 \mathcal{S}_i utilise une partie $s_{i,m}$ de la bande passante b_{e_m} du lien e_m
 P_i a besoin d'un temps $D_c \cdot \frac{1}{\min_{e_m \in \mathcal{S}_i} s_{i,m}}$ pour envoyer à son successeur un message de taille D_c
Contraintes sur la bande passante de e_m :
$$\sum_{1 \leq i \leq p} s_{i,m} \leq b_{e_m}$$
- De même il y a un chemin \mathcal{P}_i de P_i à $P_{\text{pred}(i)}$ dans le réseau, qui utilise une partie $p_{i,m}$ de la bande passante b_{e_m} du lien e_m

Exemple jouet: choix de l'anneau



- 7 processeurs et 8 liens de communications bidirectionnels
- On choisit un anneau de 5 processeurs:
 $P_1 \rightarrow P_2 \rightarrow P_3 \rightarrow P_4 \rightarrow P_5$ (on n'utilise ni Q , ni R)
- Les liens sont étiquetés de a à h
- On note b_x la bande passante du lien x

Exemple jouet : choix des chemins



De P_1 à P_2 , on utilise les liens a et b : $\mathcal{S}_1 = \{a, b\}$.

Mais de P_2 à P_1 , on utilise les liens b , g et h : $\mathcal{P}_2 = \{b, g, h\}$.

- De P_1 : à P_2 , $\mathcal{S}_1 = \{a, b\}$ et à P_5 , $\mathcal{P}_1 = \{h\}$
- De P_2 : à P_3 , $\mathcal{S}_2 = \{c, d\}$ et à P_1 , $\mathcal{P}_2 = \{b, g, h\}$
- De P_3 : à P_4 , $\mathcal{S}_3 = \{d, e\}$ et à P_2 , $\mathcal{P}_3 = \{d, e, f\}$
- De P_4 : à P_5 , $\mathcal{S}_4 = \{f, b, g\}$ et à P_3 , $\mathcal{P}_4 = \{e, d\}$
- De P_5 : à P_1 , $\mathcal{S}_5 = \{h\}$ et à P_4 , $\mathcal{P}_5 = \{g, b, f\}$

Exemple jouet: partage des bandes passantes

Pour P_1 : comme $\mathcal{S}_1 = \{a, b\}$, $c_{1,2} = \frac{1}{\min(s_{1,a}, s_{1,b})}$.

Pour P_1 : comme $\mathcal{P}_1 = \{h\}$, $c_{1,5} = \frac{1}{p_{1,h}}$.

Ensemble de toutes les contraintes de partage:

Lien a : $s_{1,a} \leq b_a$

Lien b : $s_{1,b} + s_{4,b} + p_{2,b} + p_{5,b} \leq b_b$

Lien c : $s_{2,c} \leq b_c$

Lien d : $s_{2,d} + s_{3,d} + p_{3,d} + p_{4,d} \leq b_d$

Lien e : $s_{3,e} + p_{3,e} + p_{4,e} \leq b_e$

Lien f : $s_{4,f} + p_{3,f} + p_{5,f} \leq b_f$

Lien g : $s_{4,g} + p_{2,g} + p_{5,g} \leq b_g$

Lien h : $s_{5,h} + p_{1,h} + p_{2,h} \leq b_h$

Exemple jouet: partage des bandes passantes

Pour P_1 : comme $\mathcal{S}_1 = \{a, b\}$, $c_{1,2} = \frac{1}{\min(s_{1,a}, s_{1,b})}$.

Pour P_1 : comme $\mathcal{P}_1 = \{h\}$, $c_{1,5} = \frac{1}{p_{1,h}}$.

Ensemble de toutes les contraintes de partage:

Lien a : $s_{1,a} \leq b_a$

Lien b : $s_{1,b} + s_{4,b} + p_{2,b} + p_{5,b} \leq b_b$

Lien c : $s_{2,c} \leq b_c$

Lien d : $s_{2,d} + s_{3,d} + p_{3,d} + p_{4,d} \leq b_d$

Lien e : $s_{3,e} + p_{3,e} + p_{4,e} \leq b_e$

Lien f : $s_{4,f} + p_{3,f} + p_{5,f} \leq b_f$

Lien g : $s_{4,g} + p_{2,g} + p_{5,g} \leq b_g$

Lien h : $s_{5,h} + p_{1,h} + p_{2,h} \leq b_h$

Exemple jouet: système quadratique final

MINIMISER $\max_{1 \leq i \leq 5} (\alpha_i \cdot D_w \cdot w_i + D_c \cdot (c_{i,i-1} + c_{i,i+1}))$

SOUS LES CONTRAINTES

$$\left\{ \begin{array}{lll}
 \sum_{i=1}^5 \alpha_i = 1 & & \\
 s_{1,a} \leq b_a & s_{1,b} + s_{4,b} + p_{2,b} + p_{5,b} \leq b_b & s_{2,c} \leq b_c \\
 s_{2,d} + s_{3,d} + p_{3,d} + p_{4,d} \leq b_d & s_{3,e} + p_{3,e} + p_{4,e} \leq b_e & s_{4,f} + p_{3,f} + p_{5,f} \leq b_f \\
 s_{4,g} + p_{2,g} + p_{5,g} \leq b_g & s_{5,h} + p_{1,h} + p_{2,h} \leq b_h & \\
 s_{1,a} \cdot c_{1,2} \geq 1 & s_{1,b} \cdot c_{1,2} \geq 1 & p_{1,h} \cdot c_{1,5} \geq 1 \\
 s_{2,c} \cdot c_{2,3} \geq 1 & s_{2,d} \cdot c_{2,3} \geq 1 & p_{2,b} \cdot c_{2,1} \geq 1 \\
 p_{2,g} \cdot c_{2,1} \geq 1 & p_{2,h} \cdot c_{2,1} \geq 1 & s_{3,d} \cdot c_{3,4} \geq 1 \\
 s_{3,e} \cdot c_{3,4} \geq 1 & p_{3,d} \cdot c_{3,2} \geq 1 & p_{3,e} \cdot c_{3,2} \geq 1 \\
 p_{3,f} \cdot c_{3,2} \geq 1 & s_{4,f} \cdot c_{4,5} \geq 1 & s_{4,b} \cdot c_{4,5} \geq 1 \\
 s_{4,g} \cdot c_{4,5} \geq 1 & p_{4,e} \cdot c_{4,3} \geq 1 & p_{4,d} \cdot c_{4,3} \geq 1 \\
 s_{5,h} \cdot c_{5,1} \geq 1 & p_{5,g} \cdot c_{5,4} \geq 1 & p_{5,b} \cdot c_{5,4} \geq 1 \\
 p_{5,f} \cdot c_{5,4} \geq 1 & &
 \end{array} \right.$$

Exemple jouet: moralité

Le problème est un système quadratique si

- 1 Les processeurs sont sélectionnés ;
- 2 Les processeurs sont ordonnés en anneau ;
- 3 Les chemins de communications entre les processeurs sont connus.

Autrement dit: système quadratique si l'anneau est connu.

Si l'anneau est connu:

- Graphe complet: formule.
- Graphe quelconque: système quadratique.

Exemple jouet: moralité

Le problème est un système quadratique si

- 1 Les processeurs sont sélectionnés ;
- 2 Les processeurs sont ordonnés en anneau ;
- 3 Les chemins de communications entre les processeurs sont connus.

Autrement dit: système quadratique si l'anneau est connu.

Si l'anneau est connu:

- Graphe complet: formule.
- Graphe quelconque: système quadratique.

Exemple jouet: moralité

Le problème est un système quadratique si

- 1 Les processeurs sont sélectionnés ;
- 2 Les processeurs sont ordonnés en anneau ;
- 3 Les chemins de communications entre les processeurs sont connus.

Autrement dit: système quadratique si l'anneau est connu.

Si l'anneau est connu:

- Graphe complet: formule.
- Graphe quelconque: système quadratique.

Exemple jouet: moralité

Le problème est un système quadratique si

- 1 Les processeurs sont sélectionnés ;
- 2 Les processeurs sont ordonnés en anneau ;
- 3 Les chemins de communications entre les processeurs sont connus.

Autrement dit: système quadratique si l'anneau est connu.

Si l'anneau est connu:

- Graphe complet: formule.
- Graphe quelconque: système quadratique.

Exemple jouet: moralité

Le problème est un système quadratique si

- 1 Les processeurs sont sélectionnés ;
- 2 Les processeurs sont ordonnés en anneau ;
- 3 Les chemins de communications entre les processeurs sont connus.

Autrement dit: système quadratique si l'anneau est connu.

Si l'anneau est connu:

- Graphe complet: formule.
- Graphe quelconque: système quadratique.

Et en pratique ?

On adapte notre heuristique gloutonne:

- 1 Initialement: meilleure paire de processeurs
- 2 Pour chaque processeur P_k (non encore dans l'anneau)
 - Pour chaque paire (P_i, P_j) de voisins dans l'anneau
 - 1 On construit le graphe des bandes passantes non utilisées (Sans considérer les chemins entre P_i et P_j)
 - 2 On calcule des plus courts chemins (en terme de bandes passantes) entre P_k et P_i et P_j
 - 3 On évalue la solution
- 3 On garde la meilleure solution trouvée à l'étape 2 et on recommence

+ raffinements (*max-min fairness*, résolution quadratique)

Est-ce bien raisonnable ?

- Aucune garantie, ni théorique, ni pratique
- Solution simple:
 - 1 on construit le graphe complet dont les arêtes sont étiquetées par les bandes passantes des meilleurs chemins
 - 2 on applique l'heuristique pour graphe complet
 - 3 on alloue les bandes passantes
- Résultats bien meilleurs si, dès le départ, on prend en compte les nécessaires partages de bandes passantes

Est-ce bien raisonnable ?

- Aucune garantie, ni théorique, ni pratique
- Solution simple:
 - ① on construit le graphe complet dont les arêtes sont étiquetées par les bandes passantes des meilleurs chemins
 - ② on applique l'heuristique pour graphe complet
 - ③ on alloue les bandes passantes
- Résultats bien meilleurs si, dès le départ, on prend en compte les nécessaires partages de bandes passantes

Est-ce bien raisonnable ?

- Aucune garantie, ni théorique, ni pratique
- Solution simple:
 - 1 on construit le graphe complet dont les arêtes sont étiquetées par les bandes passantes des meilleurs chemins
 - 2 on applique l'heuristique pour graphe complet
 - 3 on alloue les bandes passantes
- Résultats bien meilleurs si, dès le départ, on prend en compte les nécessaires partages de bandes passantes

Est-ce bien raisonnable ?

- Aucune garantie, ni théorique, ni pratique
- Solution simple:
 - 1 on construit le graphe complet dont les arêtes sont étiquetées par les bandes passantes des meilleurs chemins
 - 2 on applique l'heuristique pour graphe complet
 - 3 on alloue les bandes passantes
- Résultats bien meilleurs si, dès le départ, on prend en compte les nécessaires partages de bandes passantes

Est-ce bien raisonnable ?

- Aucune garantie, ni théorique, ni pratique
- Solution simple:
 - 1 on construit le graphe complet dont les arêtes sont étiquetées par les bandes passantes des meilleurs chemins
 - 2 on applique l'heuristique pour graphe complet
 - 3 on alloue les bandes passantes
- Résultats bien meilleurs si, dès le départ, on prend en compte les nécessaires partages de bandes passantes

Est-ce bien raisonnable ?

- Aucune garantie, ni théorique, ni pratique
- Solution simple:
 - 1 on construit le graphe complet dont les arêtes sont étiquetées par les bandes passantes des meilleurs chemins
 - 2 on applique l'heuristique pour graphe complet
 - 3 on alloue les bandes passantes
- Résultats bien meilleurs si, dès le départ, on prend en compte les nécessaires partages de bandes passantes

Plan de l'exposé

- 1 Présentation du problème
- 2 Réseau complet homogène
- 3 Réseau complet hétérogène
- 4 Réseau hétérogène quelconque
- 5 Plates-formes non dédiées**

Nouvelles difficultés

La puissance de calcul disponible pour chaque processeur varie au cours du temps

La bande passante disponible de chaque lien réseau varie au cours du temps

⇒ Nécessité de remettre en cause les allocations effectuées

⇒ Introduction de dynamique dans une approche statique

Une approche possible

- Si les performances constatées diffèrent « trop » des caractéristiques utilisées pour déterminer l'allocation

Critère définissant « trop » ?

- Si les performances diffèrent « beaucoup »
 - On calcule un nouvel anneau
 - On redistribue les données d'un anneau à l'autre

Critère définissant « beaucoup » ?

Coût de la redistribution ?

- Si les performances diffèrent « peu »
 - On calcule un nouvel équilibrage de la charge dans l'anneau existant
 - On redistribue les données dans l'anneau

Comment effectuer efficacement la redistribution ?

Une approche possible

- Si les performances constatées diffèrent « trop » des caractéristiques utilisées pour déterminer l'allocation

Critère définissant « trop » ?

- Si les performances diffèrent « beaucoup »
 - On calcule un nouvel anneau
 - On redistribue les données d'un anneau à l'autre

Critère définissant « beaucoup » ?

Coût de la redistribution ?

- Si les performances diffèrent « peu »
 - On calcule un nouvel équilibrage de la charge dans l'anneau existant
 - On redistribue les données dans l'anneau

Comment effectuer efficacement la redistribution ?

Conclusion

Le parallélisme « régulier » était déjà compliqué, maintenant on a

- Des processeurs de caractéristiques différentes
- Des liens de communications de caractéristiques différentes
- Des réseaux irréguliers... voire de topologie inconnue
- Des ressources dont les caractéristiques évoluent au cours du temps

Solutions: des heuristiques non garanties à des algorithmes optimaux...