

La Dissémination De Données

TIPE

Plan

- Présentation de la dissémination de données
- Résultats théoriques
- Présentation des algorithmes d'ordonnancement
- Résultats pratiques: un programme simulant un serveur Internet

Présentation de la dissémination de données

Intérêt de la dissémination?

- Environnements asymétriques
- Intérêt pour Internet:
 - Diminuer la bande passante
 - Alléger le serveur
 - SURTOUT: diminuer le temps d'attente des clients

Fonctionnement

- Approche habituelle:
 - Traitement au cas par cas
 - On sert le premier client de la liste d'attente
- Dissémination de données:
 - Diffusion de l'information dans un canal
 - On ne se préoccupe pas des clients actuellement connectés


Un exemple pour comprendre

On a deux messages A et B à diffuser.

A est quatre fois plus populaire que B

Comment minimiser le temps d'attente des clients?

Diffuser A quatre fois plus que B




$$TS(B)=1+5/2=3.5$$

$$TS(A)=1+(3/5*0.5)+(2/5*1)=1.7$$

Temps d'attente moyen: 2.06 secondes

Diffuser A deux fois plus que B



$$TS(B)=1+3/2=2.5$$

$$TS(A)=1+(2/3*1)+(1/3*0.5)=1.83$$


Temps d'attente moyen: 1.97 secondes

Résultats théoriques

Formalisation du problème

- m messages M_1, M_m , de mêmes longueurs à diffuser
- On dispose de W canaux de diffusion.
- Chaque message M_i a une popularité de p_i .

Définition d'un ordonnancement périodique




- n_i est le nombre de diffusions de M_i dans la période.
- T_j^i est l'intervalle de temps qui sépare les débuts de la $(j-1)$ ^{ième} et la j ^{ième} diffusion de M_i .

Calcul du temps d'attente moyen

Le temps d'attente moyen TS d'un ordonnancement de période T est

$$1 + \frac{1}{2T} \sum_{i=1}^m p_i \sum_{j=1}^{n_i} (T_j^i)^2$$

Représentation graphique du temps d'attente



Un minorant du temps de service

Soit

$$Min1 = \min\left(1 + \sum_{i=1}^m \left(\frac{p_i \tau_i}{2}\right)\right) \quad \text{sur le domaine} \begin{cases} \forall i \tau_i \geq 1 \\ \sum_{i=1}^m \frac{1}{\tau_i} \leq W \end{cases}$$

- $Min1$ est un minorant de tout ordonnancement périodique
- Il est atteint pour un unique τ^* .
- Un ordonnancement périodique S a un coût égal à ce minorant ssi il diffuse M_i tous les τ_i^* .

Calcul du minorant

- Le minorant est atteint pour $\tau_i' = \frac{K}{\sqrt{p_i}}$

$$\text{Où } K = \sum_{i=1}^m \frac{\sqrt{p_i}}{W}$$

- Le minorant vaut donc $1 + \left(\sum_{i=1}^m \sqrt{p_i} \right)^2 / 2W$

Complexité

- Le problème de l'ordonnancement de m messages avec coûts de diffusion sur W canaux est NP-difficile (réduction du problème de coloriage des graphes).
- Le problème reste ouvert si on enlève les coûts de diffusion

Présentation des algorithmes

Algorithme aléatoire

- On diffuse le message M_i avec une probabilité proportionnelle à $1/\sqrt{p_i}$
- Le temps d'attente est de $1/2 + \left(\sum_{i=1}^m \sqrt{p_i}\right)^2 / W$
- On obtient donc une 2-approximation


Algorithme glouton

- Soit σ_i le temps qui s'est écoulé depuis le début de la dernière diffusion du message M_i
- Le glouton diffuse le message M_i tel que $p_i \sigma_i \tau_i^*$ est maximal
- Donne toujours de meilleurs résultats que l'algorithme aléatoire


Algorithme basé sur le nombre d'or

- $\varphi = \frac{1+\sqrt{5}}{2}$ est l'irrationnel dont les multiples modulo 1 découpent $[0,1]$ le plus uniformément possible
- Ceci permet de construire un ordonnancement respectant les fréquences de diffusion en $1/W\tau_i^*$
- C'est une 9/8-approximation


Algorithme basé sur un arbre




1) On diffuse M_1



2) On diffuse M_2



3) On diffuse M_3



4) On diffuse $M_1 \dots$

Résultats expérimentaux

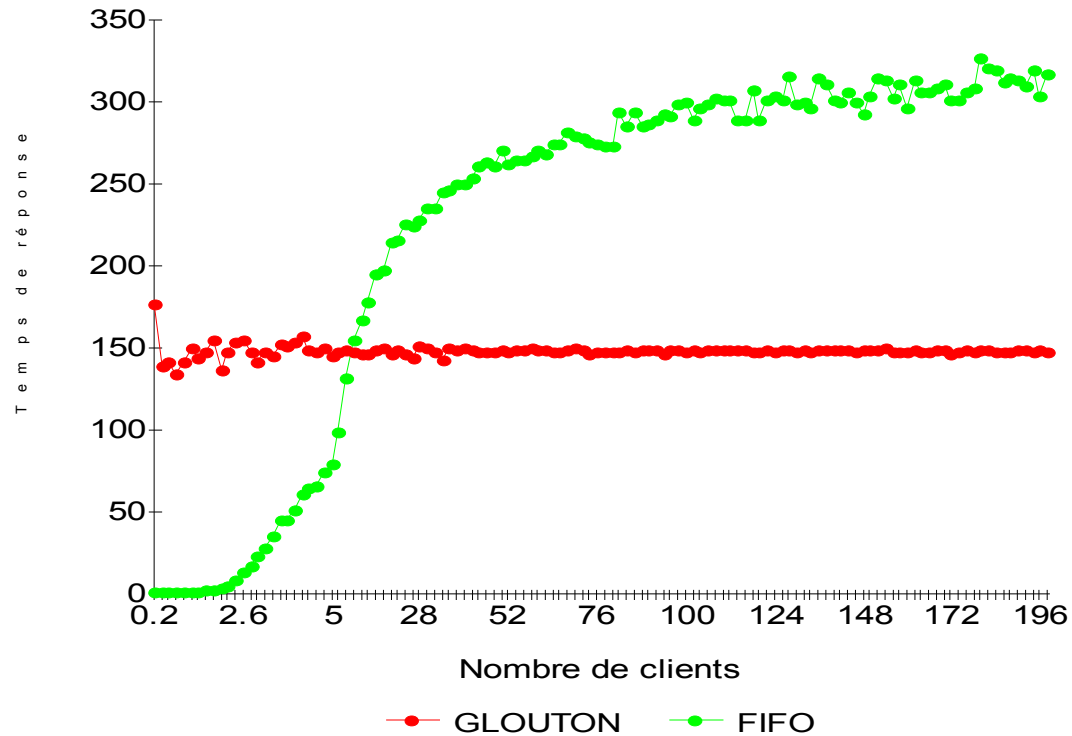
Un programme simulant un serveur
utilisant les algorithmes de
dissémination

Description du programme

- Calcul du minorant et des fréquences idéales
- Implémentation des algorithmes précédents
- Simulation de clients se connectant à un serveur diffusant les messages suivant un des algorithmes précédents

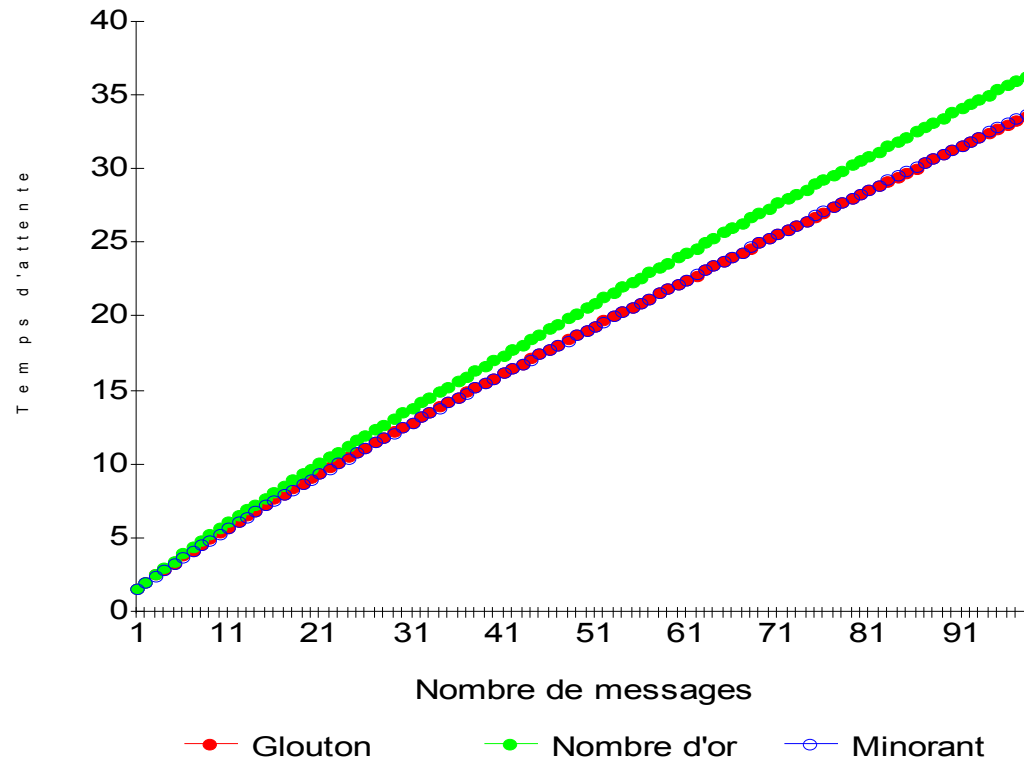
Comparaison: méthode habituelle contre dissémination

GLOUTON / FIFO




Comparaison des algorithmes de dissémination entre eux

Glouton / Nombre d'or
La popularité suit la loi de ZIPF



Variation du temps d'attente en fonction du nombre de canaux

Temps d'attente / Nombre de canaux



Conclusion

Résumé du travail

- Etude théorique partielle
- Validation expérimentale, avantages de la dissémination de données:
 - Diminuer la bande passante
 - Alléger le serveur
 - Diminuer le temps de service

Perspectives-Mise en place pratique

- Diffuser les messages les plus populaires par ce biais, les autres de la manière habituelle
- Problèmes de mise en place:
 - Comment créer un tel canal de diffusion?
 - Comment connaître la popularité des messages
- La solution: un programme dynamique