

# Partage à grande échelle de ressources hétérogènes et réparties :

## Localisation de métadonnées



[Nicolas.Lumineau@lip6.fr](mailto:Nicolas.Lumineau@lip6.fr)

Laboratoire d'Informatique de Paris VI (LIP6 – Pôle IA)



Séminaire CDS – 12/03/2004

## Projet PADOUE

**Partage de DONNÉES Utilisées en Environnement**


Page web : <http://www-poleia.lip6.fr/padoue>

Projet pluridisciplinaire de l'ACI GRID : 2002-2005



## Contexte

Accumulation de grandes quantités de ressources autonomes et inexploitées



MD: MétaDonnées

## Objectifs

- Construire un réseau de partage de métadonnées qui ...
  - Passe à l'échelle
  - Gère plusieurs schémas de MDs différents
  - Permet la localisation efficace de métadonnées pertinentes

## Plan


- Choix architecturaux
  - Stockage des Métadonnées
    - Les Systèmes Pair à Pair
  - Accès aux Métadonnées
    - Couplage avec le médiateur «LeSelect»
  - Proposition d'architecture
- Optimisation du processus de localisation
  - La sémantique de PADOUE
  - Connaissance Réseau
    - Système VENISE
  - Connaissance Communautaire
    - Liens intercommunautaires
  - Connaissance des Requêtes
    - Délégation de charge
- Bilan

## Les Réseaux Pair à Pair

- Relation d'*égal à égal* entre les nœuds du réseau:  
chaque nœud est à la fois client et serveur.
- Caractéristiques principales:
  - Pas de connaissance globale du réseau
  - Pas de coordination globale des nœuds
  - Chaque nœud ne connaît que les nœuds constituant son voisinage
  - Toutes les données sont accessibles à partir de n'importe quel nœud
  - Volatilité des nœuds

## Processus de propagation des requêtes

Requête Q




## Classification des différents systèmes P2P

- P2P Pur (GNUTELLA)
  - Respect des caractéristiques précédentes
- P2P Hybride (Napster)
  - Données distribuées mais index centralisé
- P2P Structuré (Chord, P-Grid, CAN, ...)
  - Index distribué et stocké par DHT (Distributed Hash Tables)
- P2P Hiérarchique (Super-Peer, Kazaa, ...)
  - Couplage C/S et P2P
- P2P Sémantique (SON, Routing Indices, ...)
  - P2P Pur avec routage enrichi de critères sémantiques

# Architecture de médiation

Objectif: Accès transparent aux données hétérogènes




# Couplage P2P/médiateur

- Utilisation du médiateur «LeSelect»
  - Diversité des schémas de Métadonnées
- Problématique:
  - La clause FROM des requêtes de médiation
- Proposer une utilisation du médiateur de manière à permettre le processus de propagation des requêtes

# Gestion des requêtes


## P2P

(propagation)



Connaissance des nœuds voisins  
Décentralisation de l'interrogation

## LeSelect (interrogation précise)




Connaissance de tous les nœuds  
Centralisation de l'interrogation

# Double utilisation du médiateur


## Locale

(accès aux métadonnées)




## Classique

(accès aux ressources)



# Proposition d'architecture



## Plan

- Choix architecturaux
  - Stockage des Métadonnées
    - Les Systèmes Pair à Pair
  - Accès aux Métadonnées
    - Couplage avec le médiateur «LeSelect»
  - Proposition d'architecture
- Optimisation du processus de localisation
  - La sémantique de PADOUE
  - Connaissance Réseau
    - Système VENISE
  - Connaissance Communautaire
    - Liens intercommunautaires
  - Connaissance des Requêtes
    - Délégation de charge
- Bilan

## La Sémantique de PADOUE (1)

### ■ Connaissance sur le réseau

#### ■ Vecteur Thématique

<i>Thème</i>	"climatologie"	"hydrologie"	"océanologie"	"océanographie"	...
<i>Proportion</i>	0,35	0,25	0,40	0	...

### ■ Connaissance sur les utilisateurs

#### ■ Vecteur Communauté

<i>Thème</i>	"climatologie"	"hydrologie"	"océanologie"	"océanographie"	...
<i>Présence</i>	1	0	1	0	...

## La Sémantique de PADOUE (2)

### ■ Connaissance sur les requêtes

#### ■ Catégories de requêtes


##### ■ Requête Générale (RG)

- interrogation du noyau des MDs

##### ■ Requête Spécifique (RS)


- interrogation du noyau + attributs métiers des MDs

MD



	Titre	Date	Climat	Unité	...
	Relevé Pluviométrique	2003	Océanique	Cm	...

## Bilan des Sémantiques



## Complémentarité des approches


- Connaissance Réseau (Vecteur Thématique)  
↳ **Organisation du réseau**
- Connaissance Communautaire (Vecteur Communautaire)  
↳ **Optimisation du routage des requêtes**
- Connaissance des requêtes (Catégories de requêtes)  
↳ **Répartition de la charge des noeuds**

## Organisation du réseau

- **Objectif:**  
Rapprocher logiquement les nœuds sémantiquement proches
- **Contrainte:**  
Pas de connaissance globale du réseau
- **Solution:**  
Clusterisation du réseau par technique d'apprentissage


## Intérêt de la Clusterisation

- Réduire le nombre de sauts nécessaires à la localisation de métadonnées pertinentes



Réseau NON clusterisé

(Construction aléatoire des voisinages)



Réseau clusterisé


(Construction par sélection des voisins les plus pertinents)

# VENISE

## serVice of Node Insertion in Semantic clustEr

### ■ Rôle:

Service Web qui détermine le nœud du réseau le plus pertinent pour gérer l'insertion d'un nouveau nœud.




# VENISE

## serVice of Node Insertion in Semantic clustEr


### ■ Rôle:

Service Web qui détermine le nœud du réseau le plus pertinent pour gérer l'insertion d'un nouveau nœud.




## Entrée de Cluster

- Représentation symbolique d'un cluster,
  - stockée par le service web
  - qui pointe sur le nœud du cluster en charge de l'insertion des nouveaux nœuds
  - qui contient une représentation sémantique agrégée de l'ensemble des nœuds du cluster: *Vecteur d'Agrégation*




## Protocole d'insertion de nœud

- Architecture générale



Calcul de la distance entre le Vecteur Thématique de N1 et le Vecteur d'Agrégation de chaque Entrée de cluster.


L'entrée élue est celle qui minimise cette distance




$$EC1 = \arg \min_{e \in E} \| vt_{N1} - va_e \|^2$$

# Protocole d'insertion de nœud

## ■ Architecture générale



Mise à jour des Vecteurs d'Agrégation de l'Entrée de Cluster sélectionnée (maintien de la représentation sémantique du cluster) et des Entrées de Cluster voisines (maintien d'une cohérence sémantique inter-clusters).



$$va_e \leftarrow va_e + \alpha.(vt_{N1} - va_e)$$

Maintien des liens physique inter-clusters (pour conserver la connexité du réseau)

# Optimisation du routage des requêtes

## ■ Objectif:

Exploitation des communautés d'utilisateurs

## ■ Contrainte:


Pas de définition globale des communautés

## ■ Solution:

Utilisation des liens entre les communautés distantes de centres d'intérêt communs


## Définition des communautés

- Définition des *Vecteurs Communautés* sur chaque noeud



## Les expériences d'une communauté


- Les Liens de Pertinence basés sur le feedback des membres d'une communauté sur les noeuds filtrant leurs requêtes
- Représentation :  
( *IP* du noeud pertinent , *Nom de communauté*, *feedback agrégé* )



## La ressemblance entre communautés

- Les Liens intercommunautaires basés sur la similarité entre communautés.
- Représentation :

(Nom communauté locale, IP du noeud distant, nom de communauté distante, fraîcheur du lien )




## Métriques de comparaison des communauté

- Gestion des liens inter-communautaires:
  - Approche statique  
Par dénombrement des thèmes communs entre deux Vecteurs Communautés  
(def-similarité)
  - Approche dynamique  
Par comparaison des feedbacks agrégés des communautés  
(exp-similarité)


## Def-similarité:

Création des liens inter-communautaires




## Exp-similarité :

Mise à jour des liens inter-communautaires





## Délégation du traitement des requêtes générales



## Bilan & Travaux Futurs

Architecture Pair à Pair intégrant un médiateur pour le partage de métadonnées.

3 axes de recherche pour l'optimisation du processus de propagation des requêtes:

- Clusterisation du réseau basée sur le contenu sémantique des nœuds.
  - Introduction de critères géographique dans le choix des voisins (clusters à multi-entrées)
- Partage de l'expérience des communautés d'utilisateurs pour réduire le nombre de nœuds sur lesquels la requête est exécutée.
  - Utilisation de l'usage pour compenser le manque d'expériences des communautés
- Répartition de charge des requêtes en fonction de leur catégorie.
  - Protocole de négociation pour la délégation de requêtes

<http://www-poleia.lip6.fr/padoue>



## Partenaires

- LIP6 (Université Paris 6)
  - A. Doucet, N. Lumineau, S. Gańczarski, B. Defude(INT)
- INRIA (Projet Caravel)
  - E. Simon, JP Matsumoto
- LIRMM (Université de Montpellier)
  - T. Libourel
- Cemagref (Lisc Clermont-Ferrand, UMR 3S Montpellier)
  - G. Bonnet, P. Maurel, A. Miralles
- IRD (Montpellier)
  - J.C.Desconnets, N. Moyroud
- CDS (Strasbourg)
  - F. Genova, A. Schaaff