

Mesure et Analyse de l'activité (pédophile) sur les réseaux P2P

Ludovic Denoyer - Equipe MALIRE
Guillaume Valadon – Equipe Complex Networks

Contexte

- Etude des réseaux d'échange / réseaux sociaux
 - Réseaux large scale
- Cas d'application: Projet MAPAP – Analyse de la pédophilie sur les réseaux P2P
- Trois axes de recherche:
 - Mesure sur les réseaux
 - Influence de la mesure
 - Analyse de la topologie des réseaux
 - Analyse de communautés
 - Analyse de contenu
 - Analyse conjointe structure/contenu

Equipe Complex networks

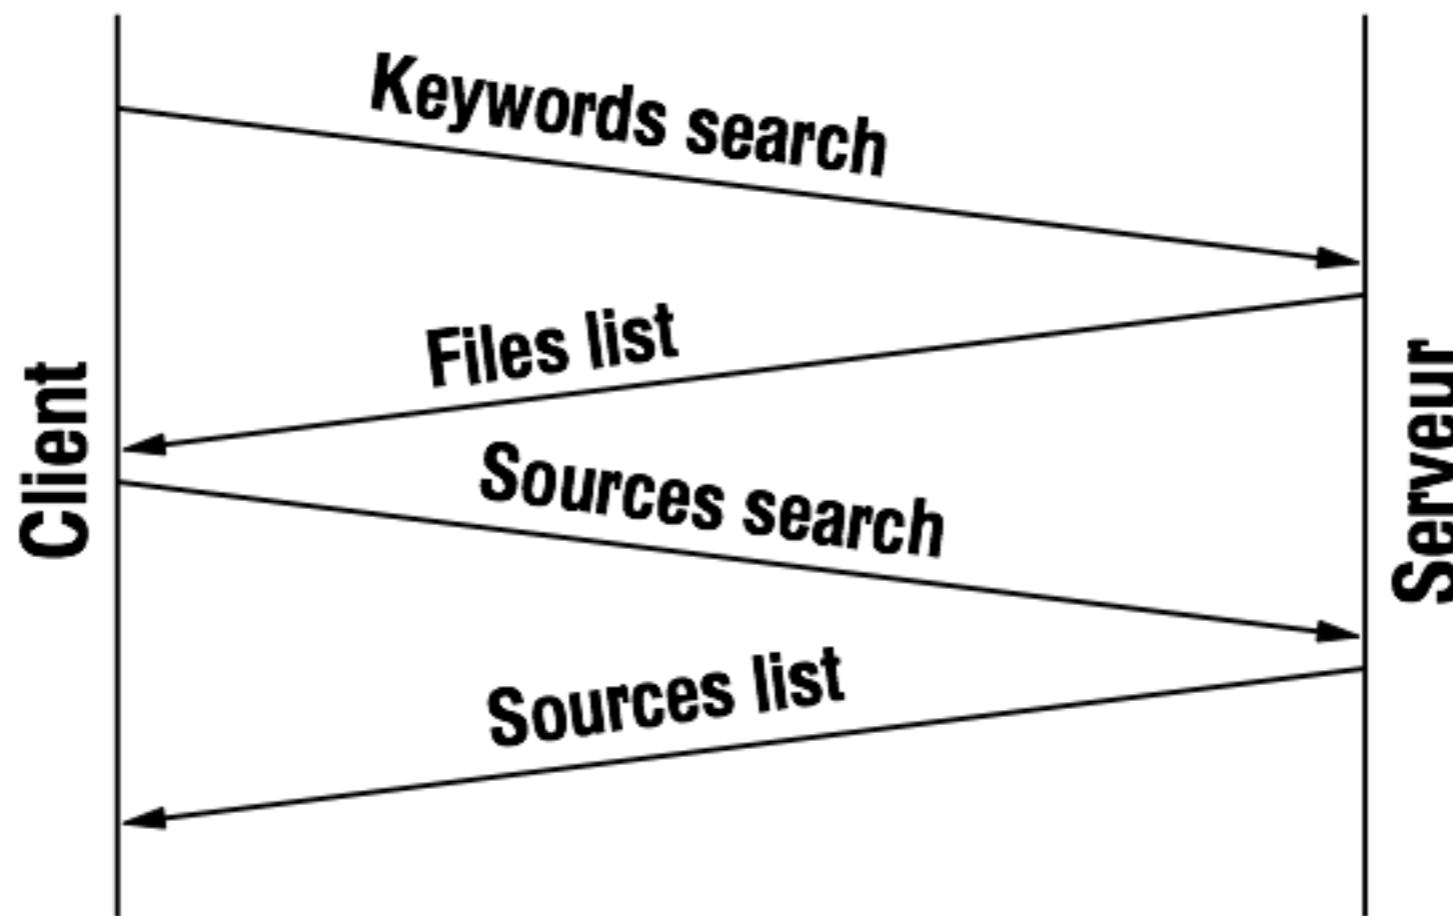
Equipe MALIRE

Problématiques de mesure

- Etude des échanges sur les réseaux P2P
 - Diffusion de fichiers
 - Communautés d'intérêts
 - Popularité
- Motivations
 - Développer de nouveaux protocoles
 - Détection du contenu caché
 - Simulation de protocole et d'échanges
 - Analyser un certain type d'activité (pédophile)

Exemple: Echanges eDonkey

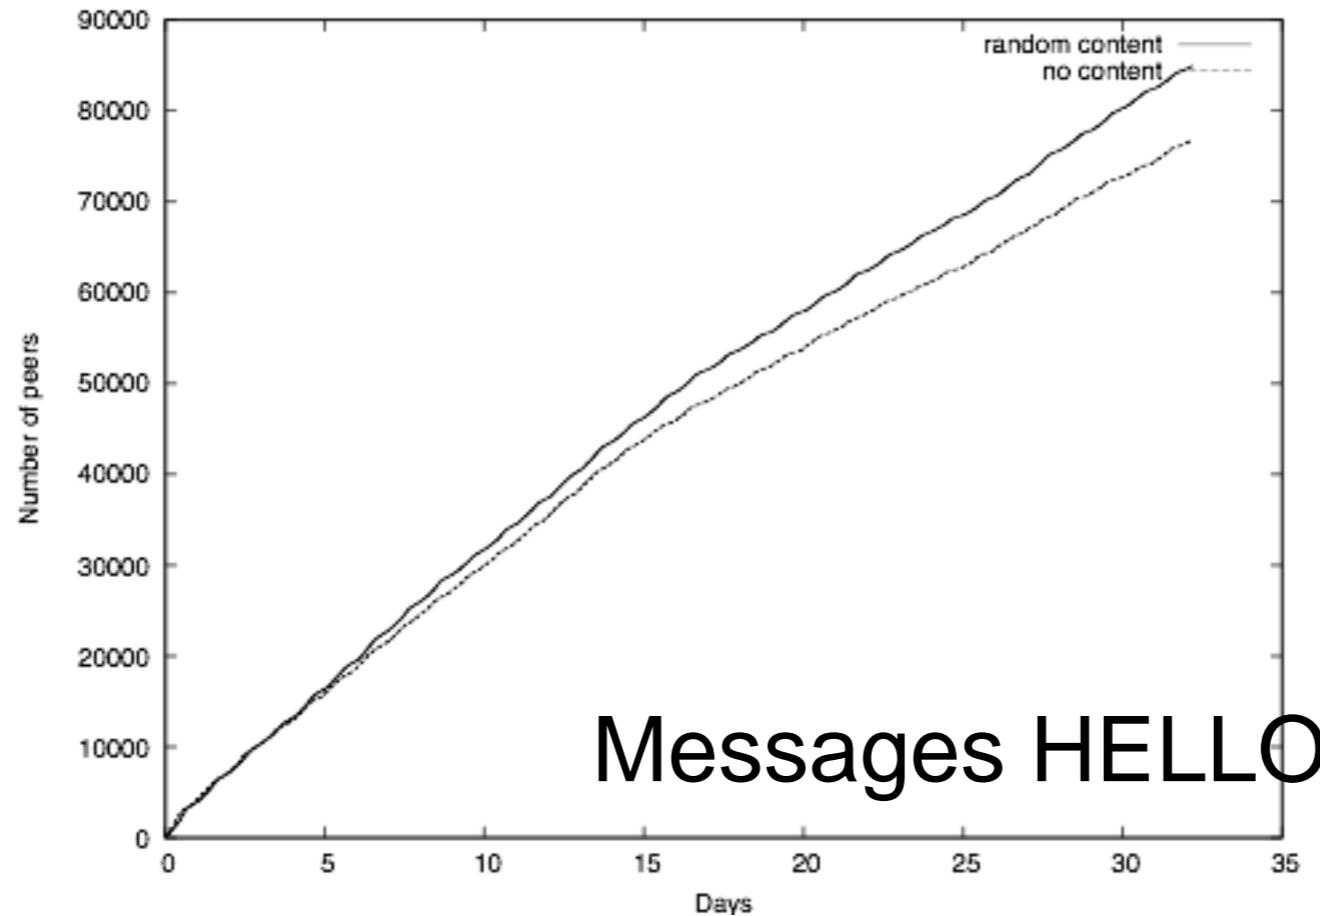
1. Entre clients: telechargement de fichiers
2. Entre serveurs: données statistiques
3. Client-serveurs: Recherche de fichiers



Méthodologie de collecte

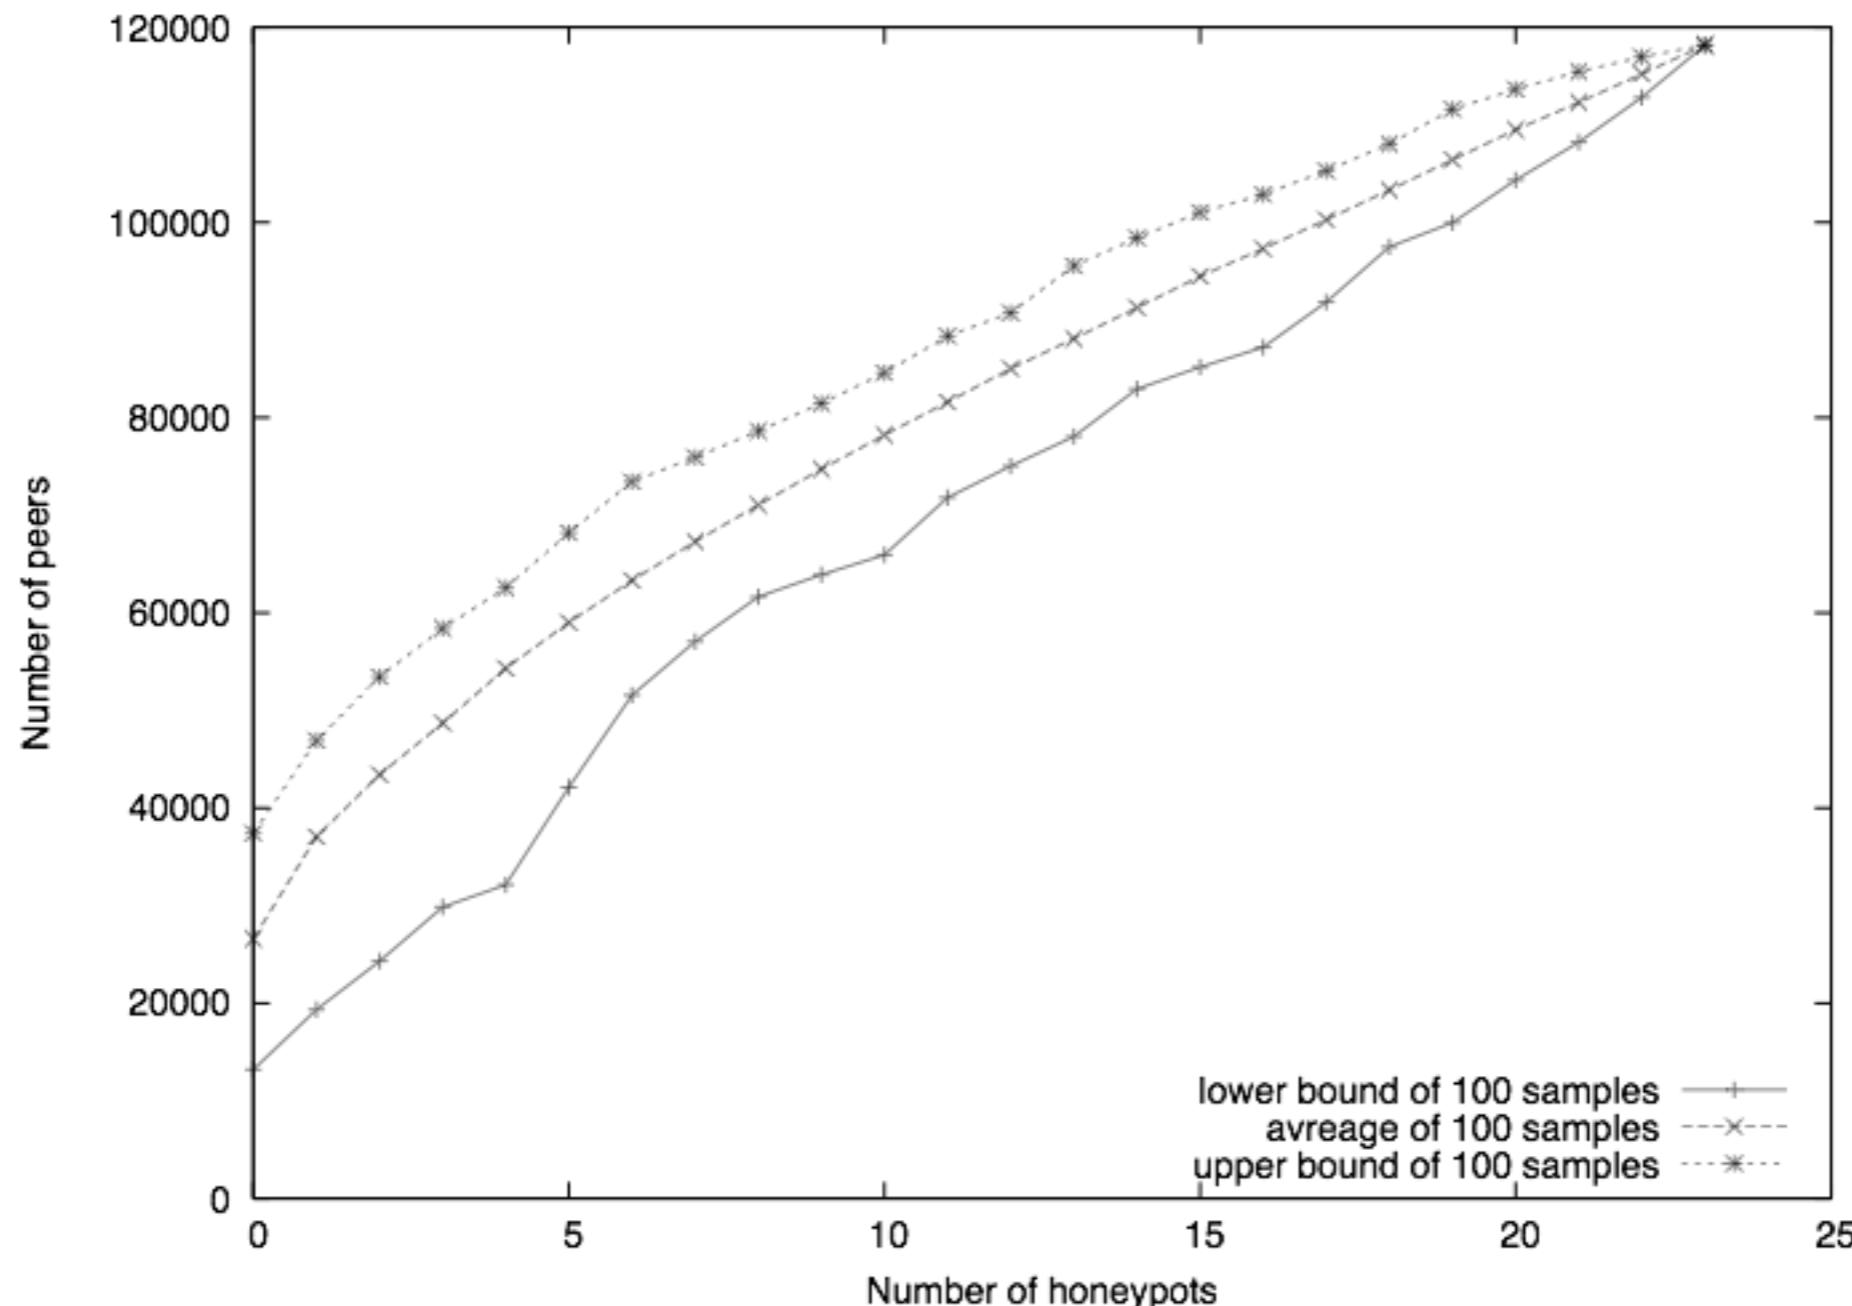
- Différents types:
 - Collecte passive
 - Collecte active
- Problèmes liés aux mesures:
 - Efficacité de la collecte
 - Qualité des observations
 - Paramètres utilisés pour les mesures

Paramètres : contenu vide ou aléatoire



- Problème légal : on ne peut pas envoyer de contenu
- But : voir un maximum de clients
- On voit plus de clients avec la stratégie aléatoire

Paramètres : nombre d'agents

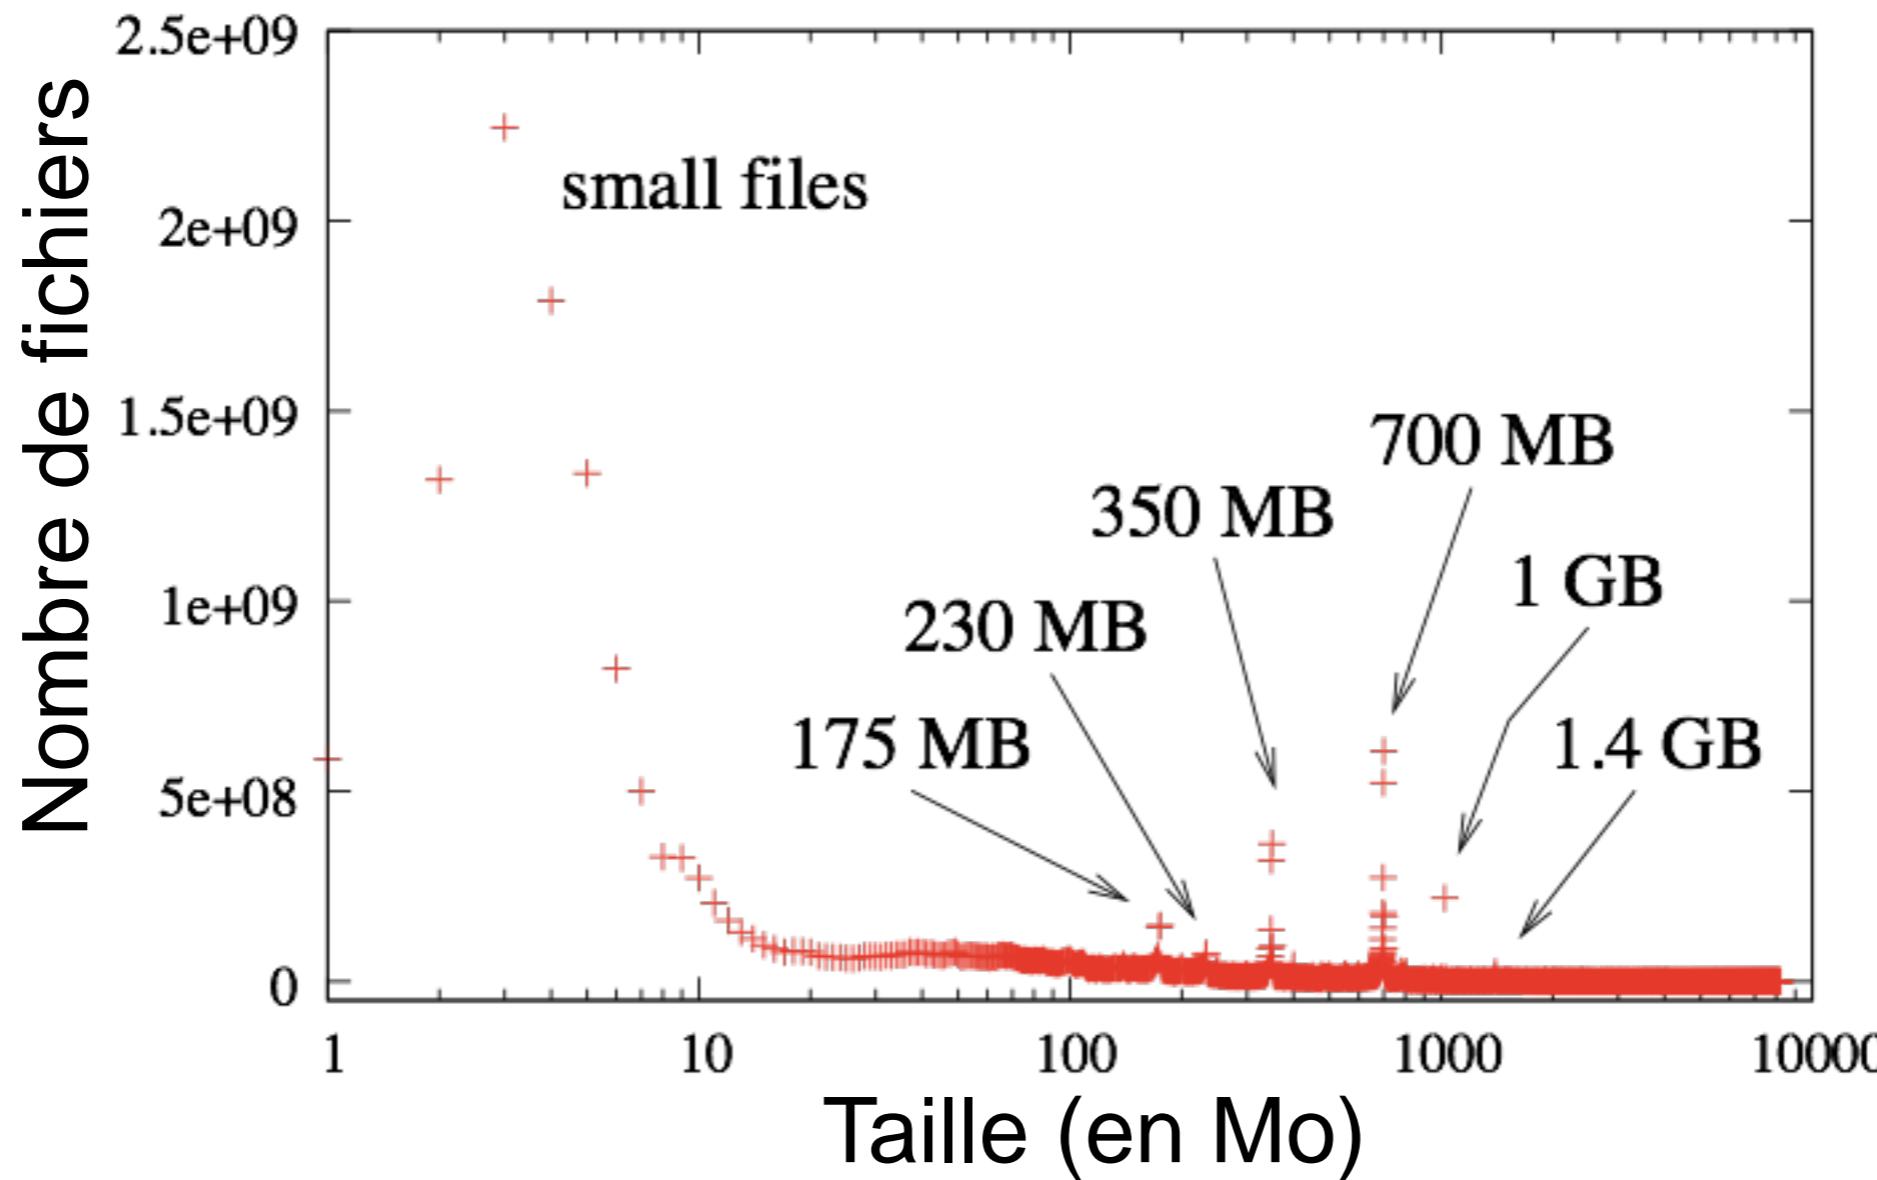


- On voit plus de clients lorsque le nombre d'agents augmente

Capture passive sur eDonkey

- 10 semaines de mesures sur un serveur
 - ~500 GB de XML compressé
 - ~ 10 milliards de messages
 - ~ 90 millions de clients
 - ~ 280 millions de fichiers différents
- Données anonymisées disponibles ici :
<http://antipaedo.lip6.fr>

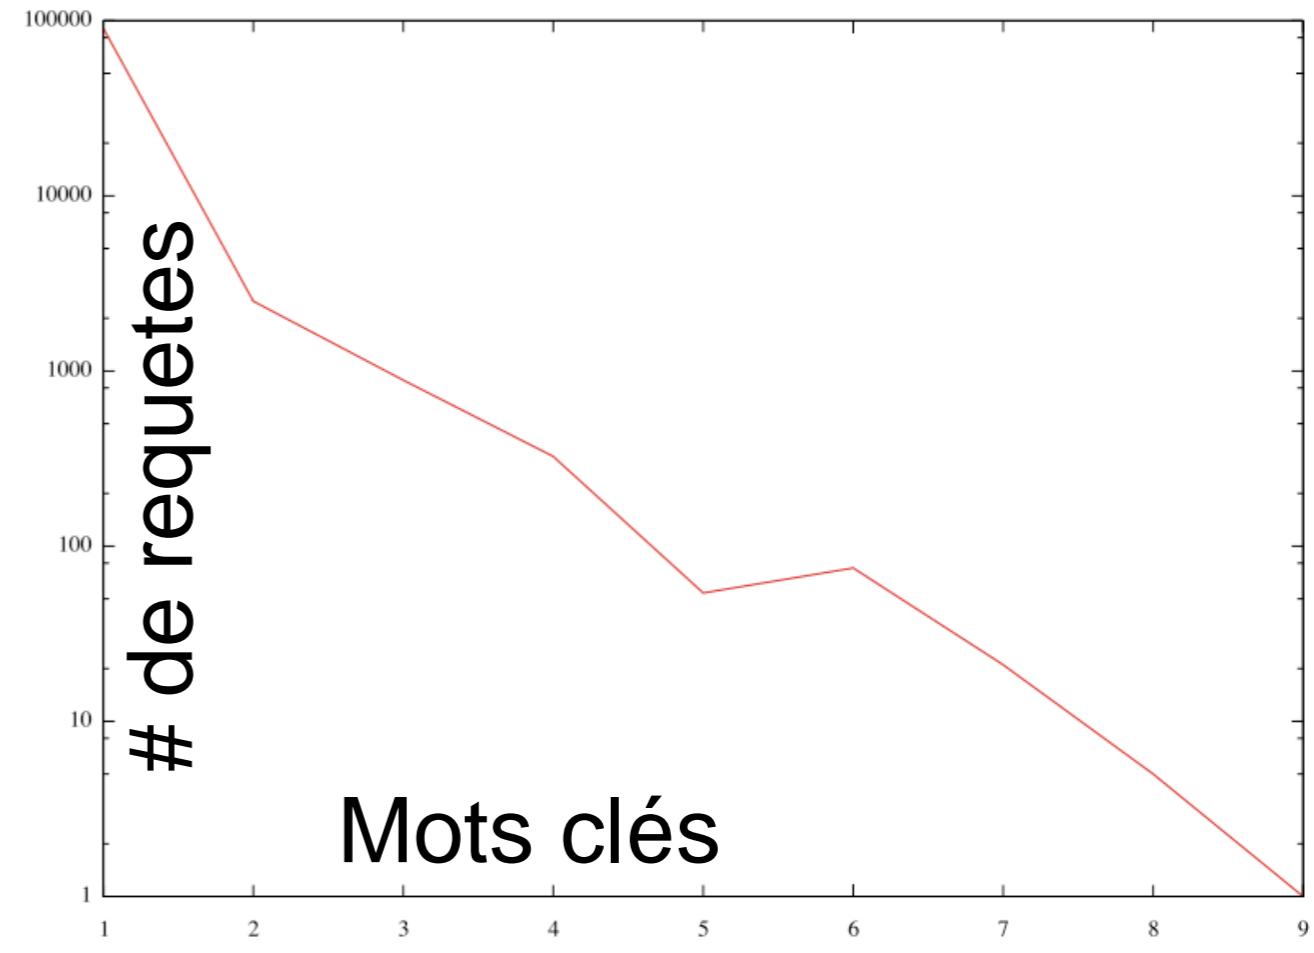
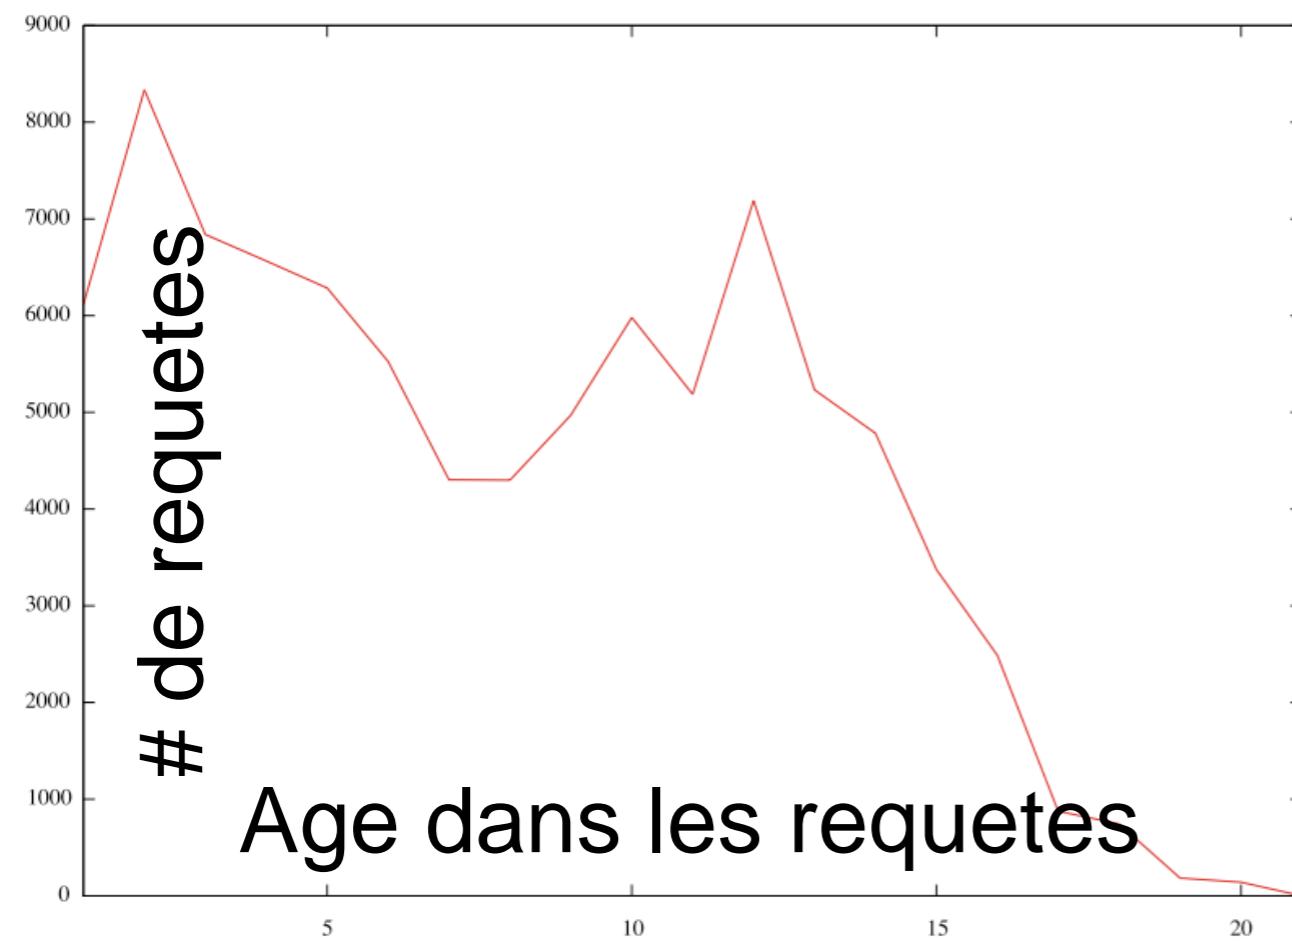
Analyse des traces collectées



- Taille d'un CD-ROM et fractions (1/2, 1/3, et 1/4)
 - relation avec les tailles des supports classiques

Contenu pédophile

	Requête s	Nom de fichiers
Mots clés pédophiles	94288	7293
Ages (XYyo, XYyr)	56672	10026

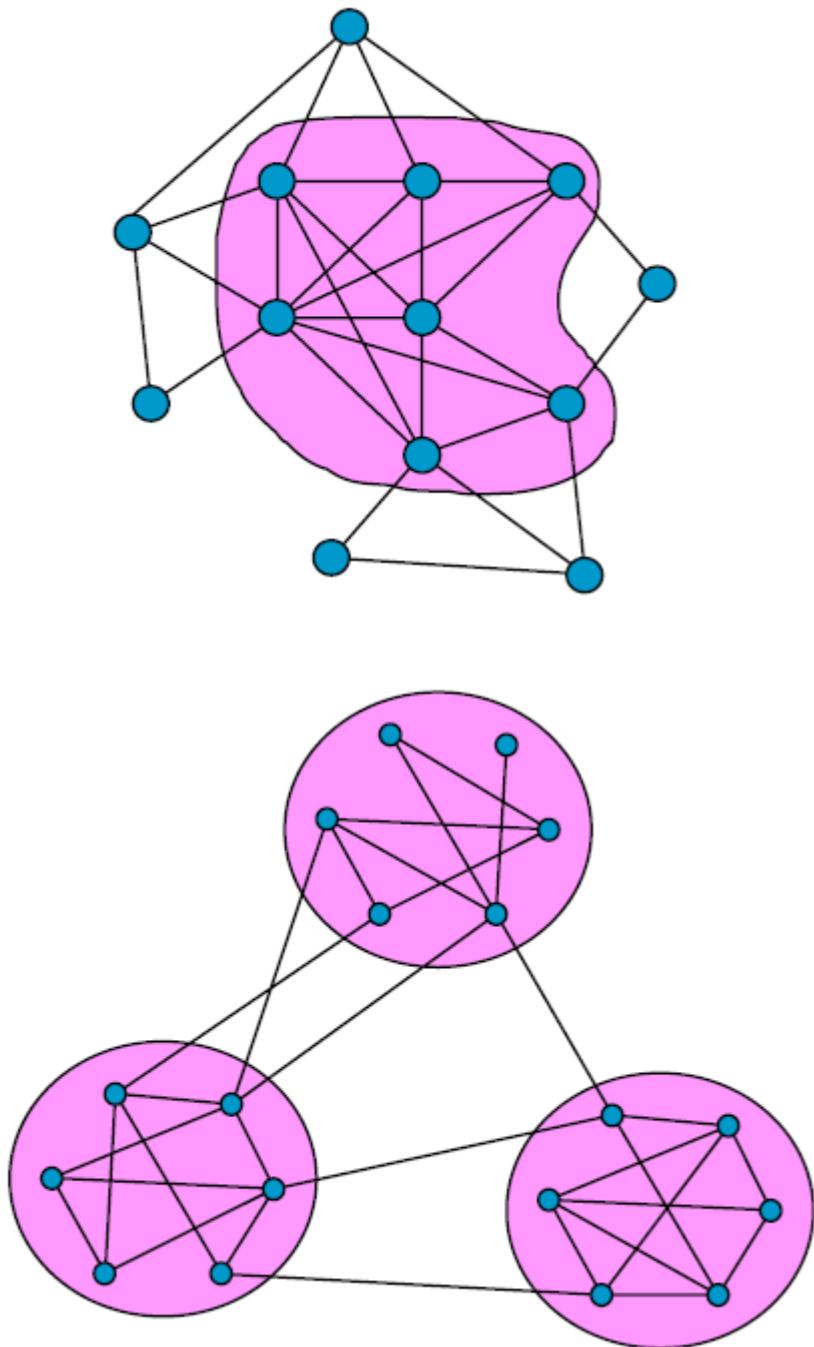


Analyse de topologie et de contenu

Analyse de topologie et de contenu

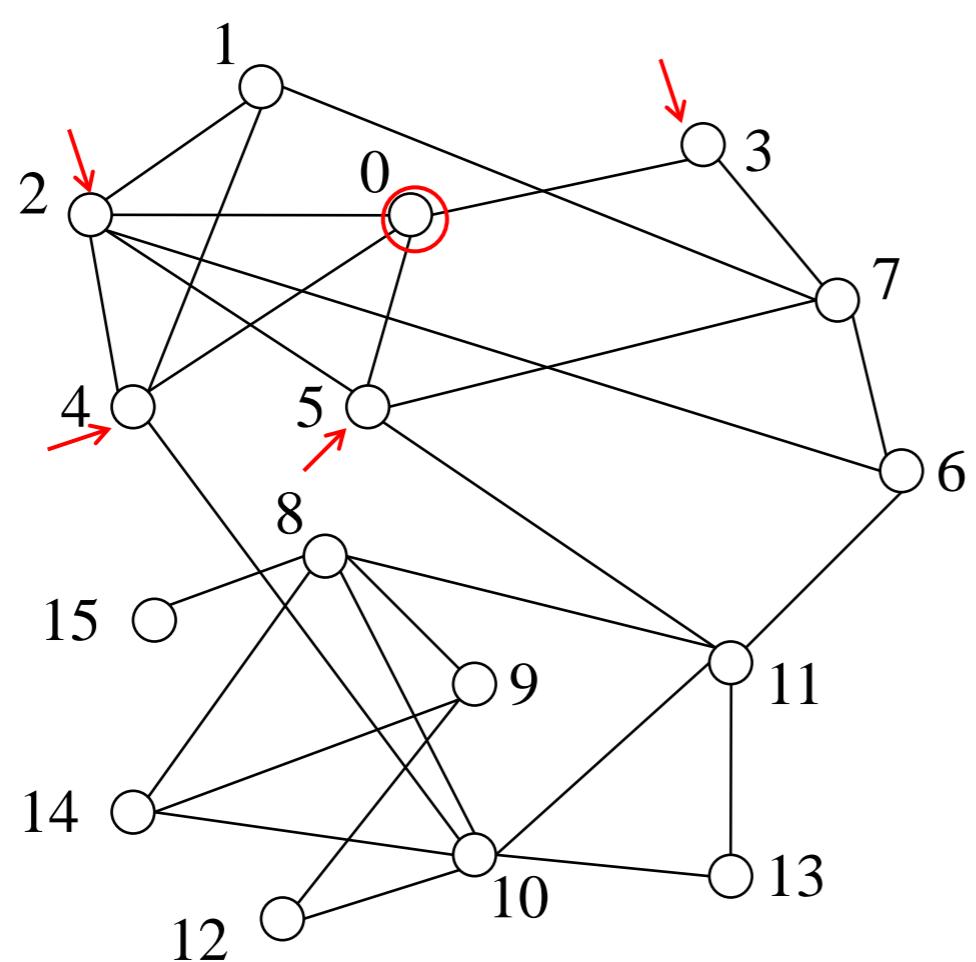
- Nécessité d'analyser les données collectées de manières « rusée »
 - Non supervisé: Détection automatique de communautés (clusters d'utilisateurs, de fichiers,)
 - Supervisé : Etiquetage des données
 - Détection d'utilisateurs/mots-clefs pédophiles
- Utilisation simultanée de l'information de structure et de contenu

Analyse de communautés topologiques



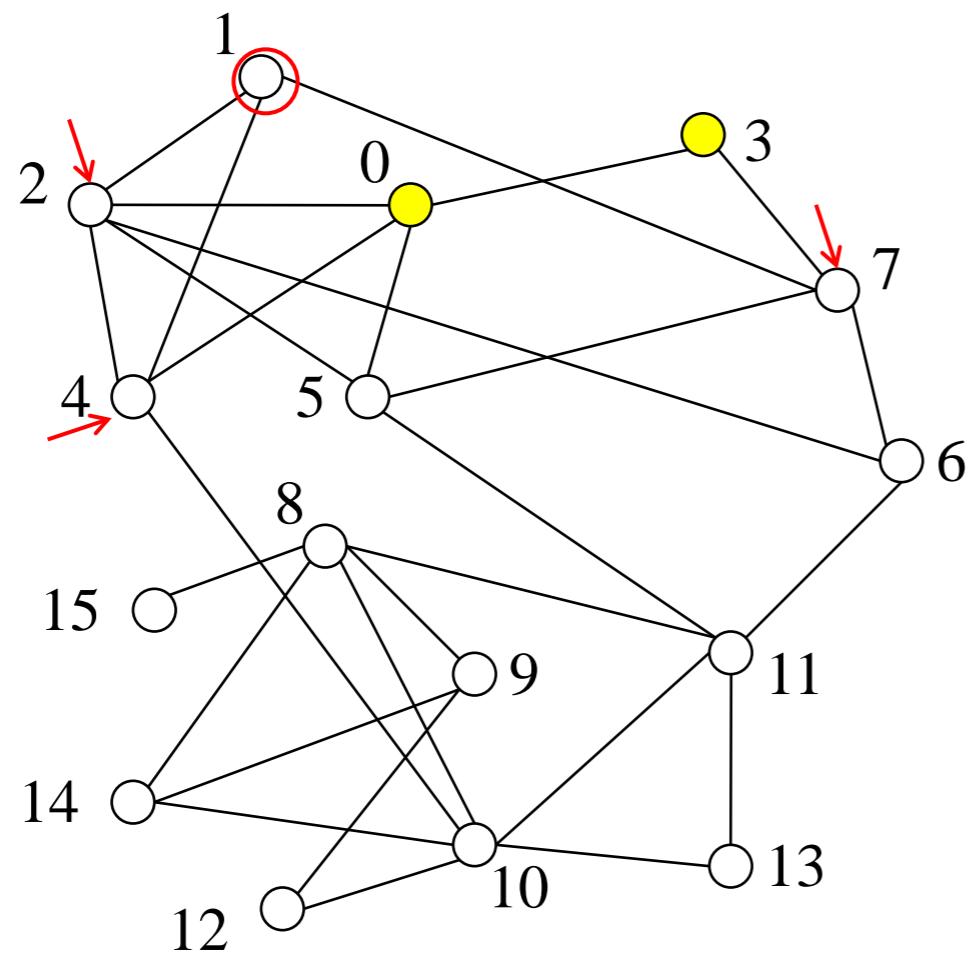
- Détection de composantes:
 - Dont les éléments sont fortement connectés
 - Dont les éléments sont faiblement connectés avec ceux des autres communautés
- Différentes approches
 - Clustering hiérarchique
 - Approche par division
 - Approche par méthode de monte-carlo
- Nécessité de développer des méthodes permettant le traitement de très grandes masses de données

Illustration

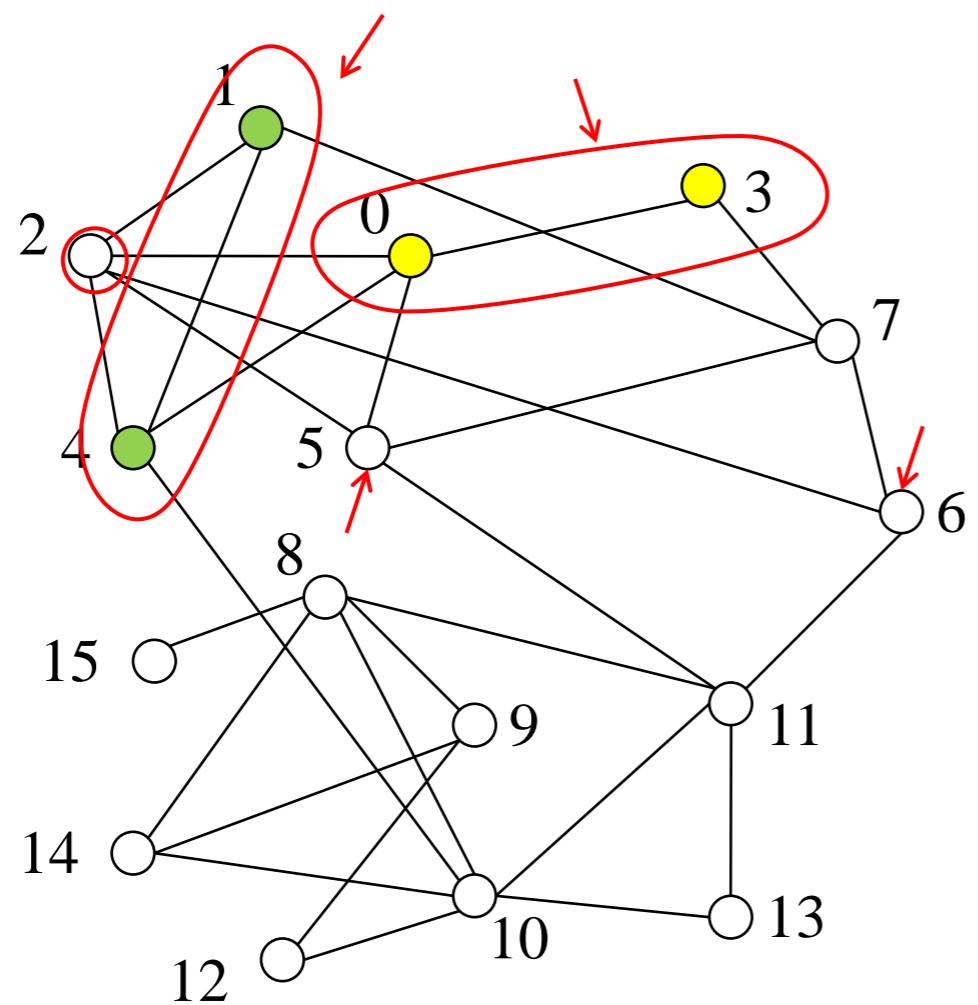


Pass 1 – Iteration 1
Each node belongs to an
atomic community

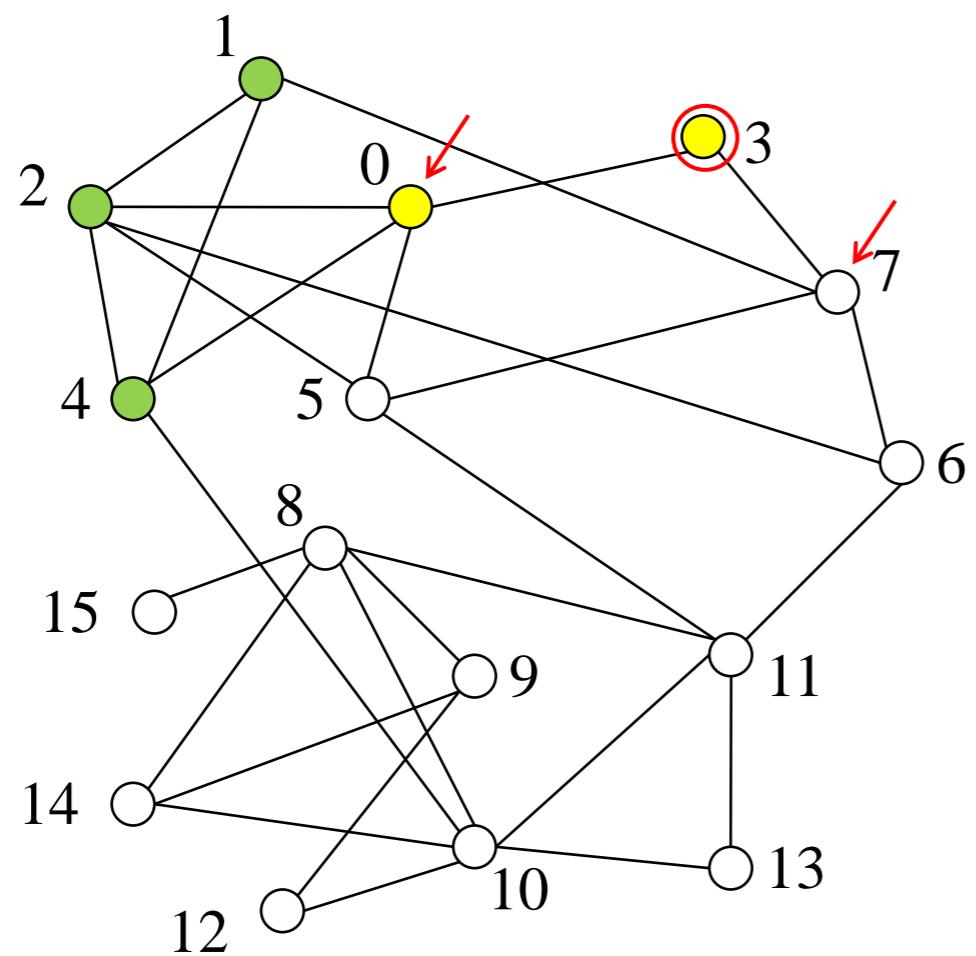
Illustration



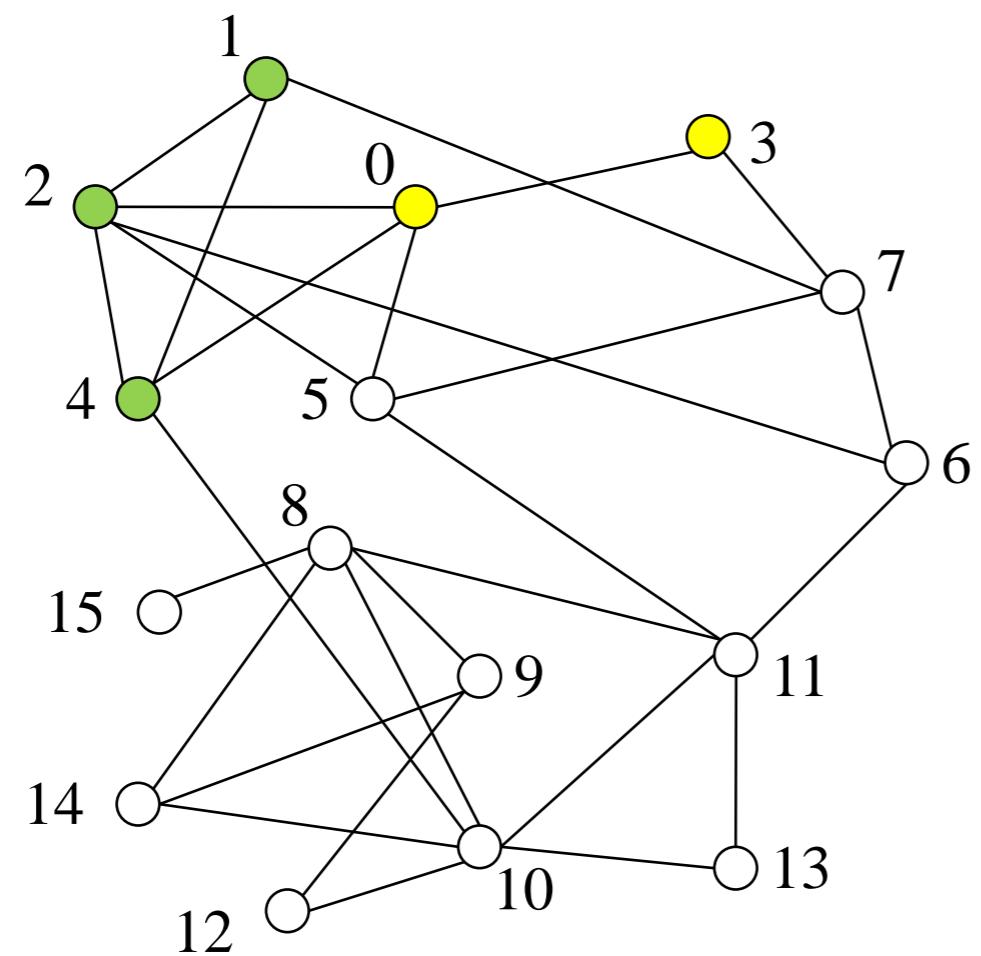
Illustration



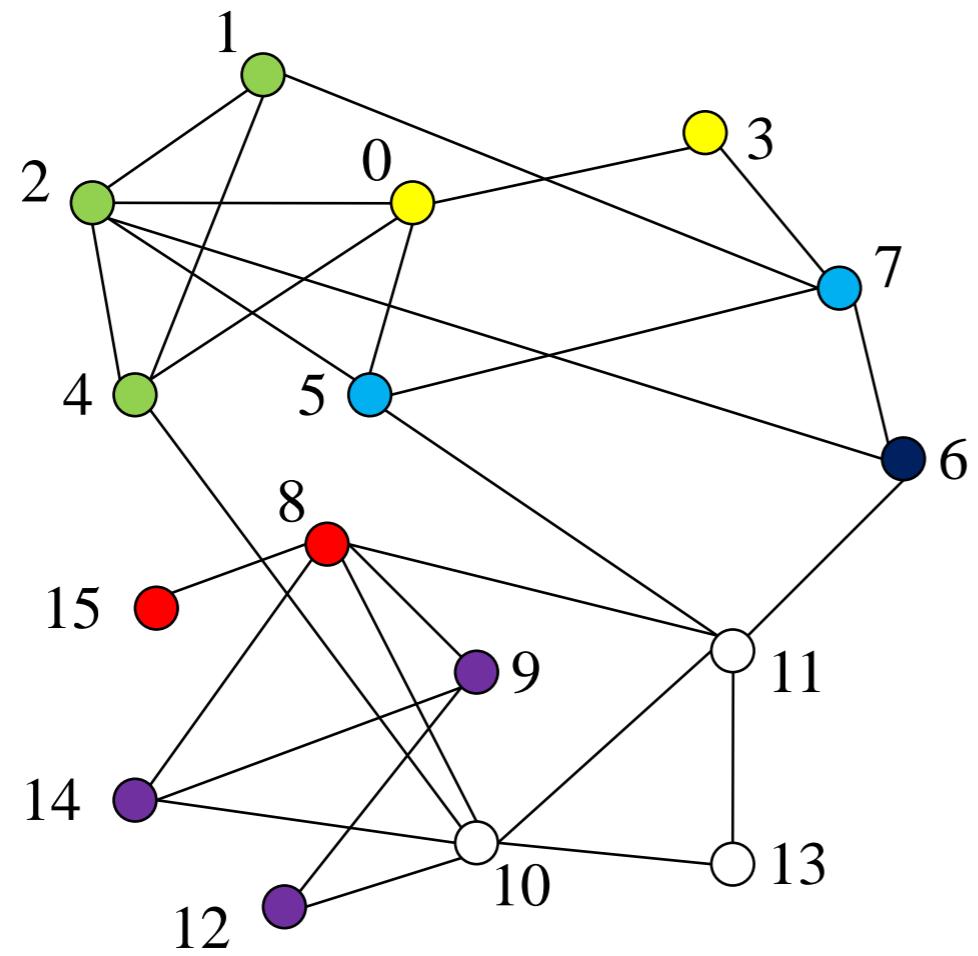
Illustration



Illustration



Illustration



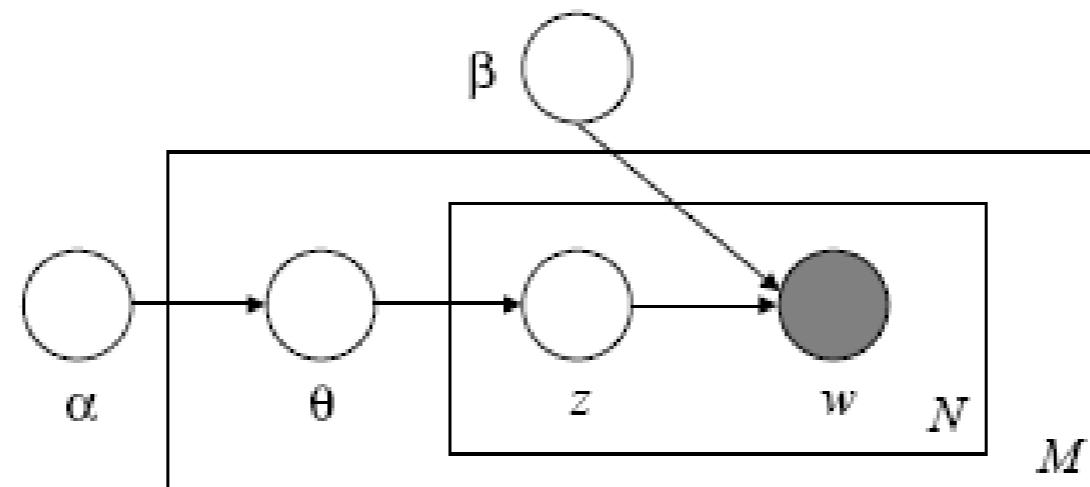
Analyse de communautés topologiques

- Limites: pas d'utilisation du contenu
 - Pas de détection de communautés thématiques
 - Deux communautés séparées peuvent avoir le même contenu
 - Pas de prise en compte de la description des éléments (utilisateurs par exemple)

Détection de communautés

Structure+Contenu

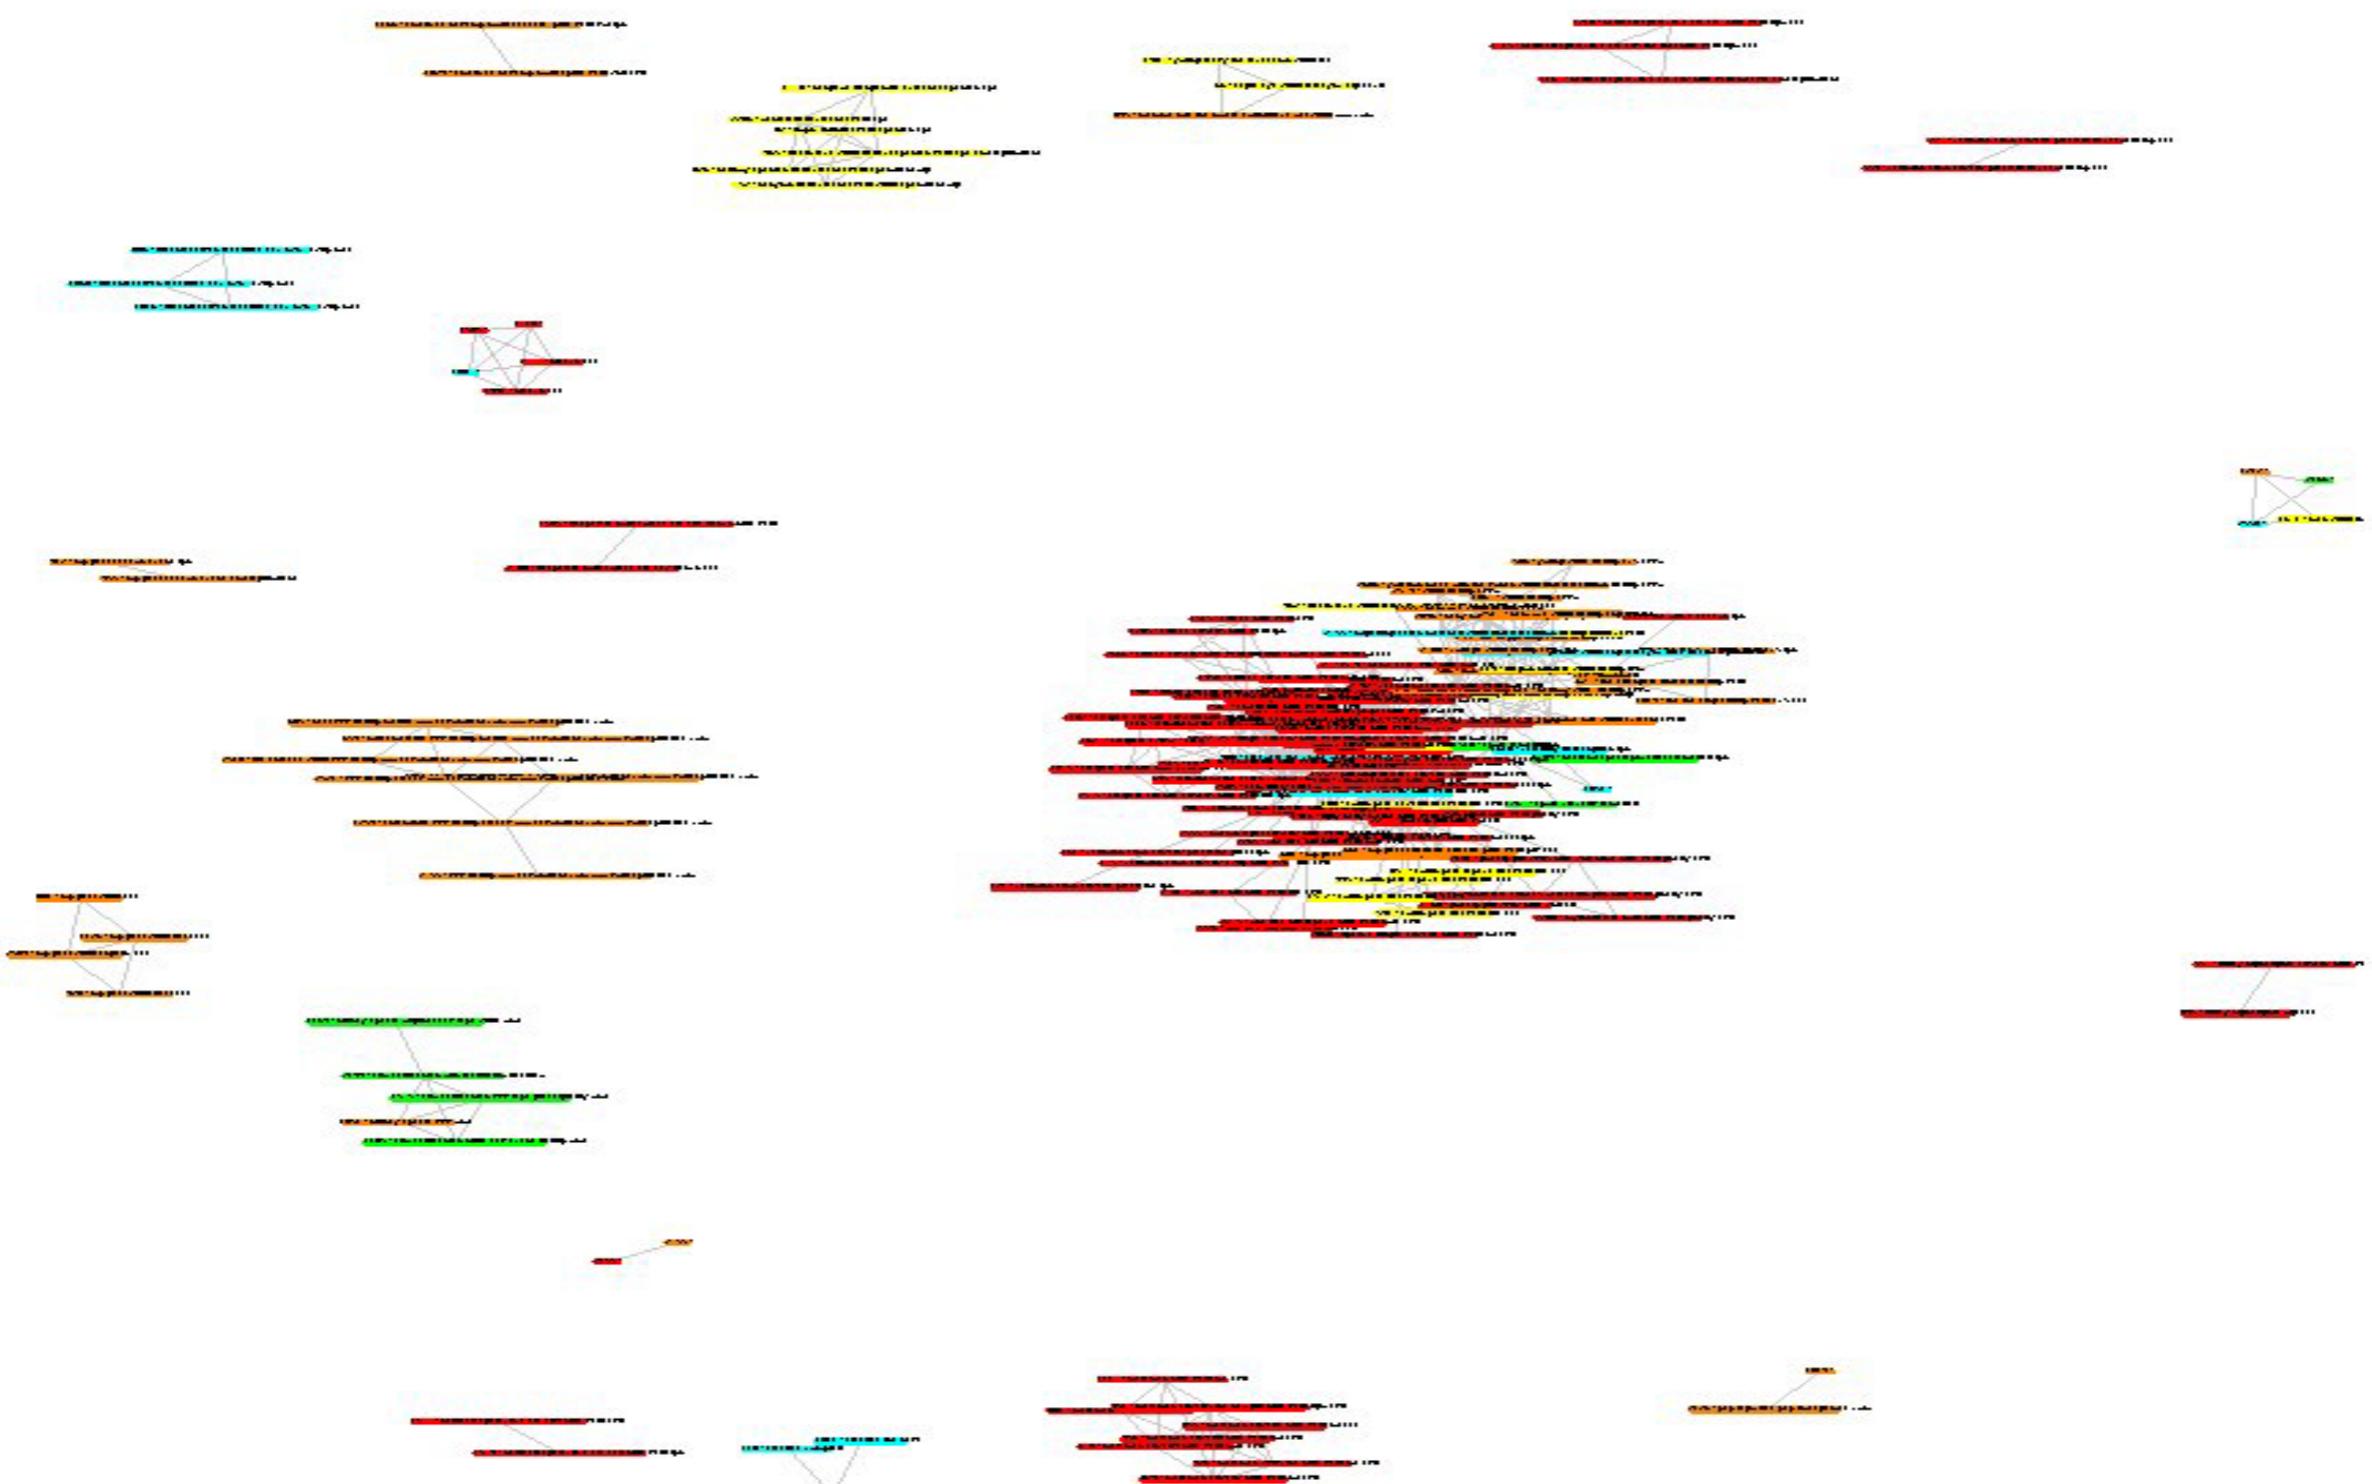
- Méthodes à base de modélisation par variable latentes
 - PLSA, LDA, méthodes spécifiques au P2P



- Extraction conjointes d'informations sur les thématiques, les fichiers et les utilisateurs

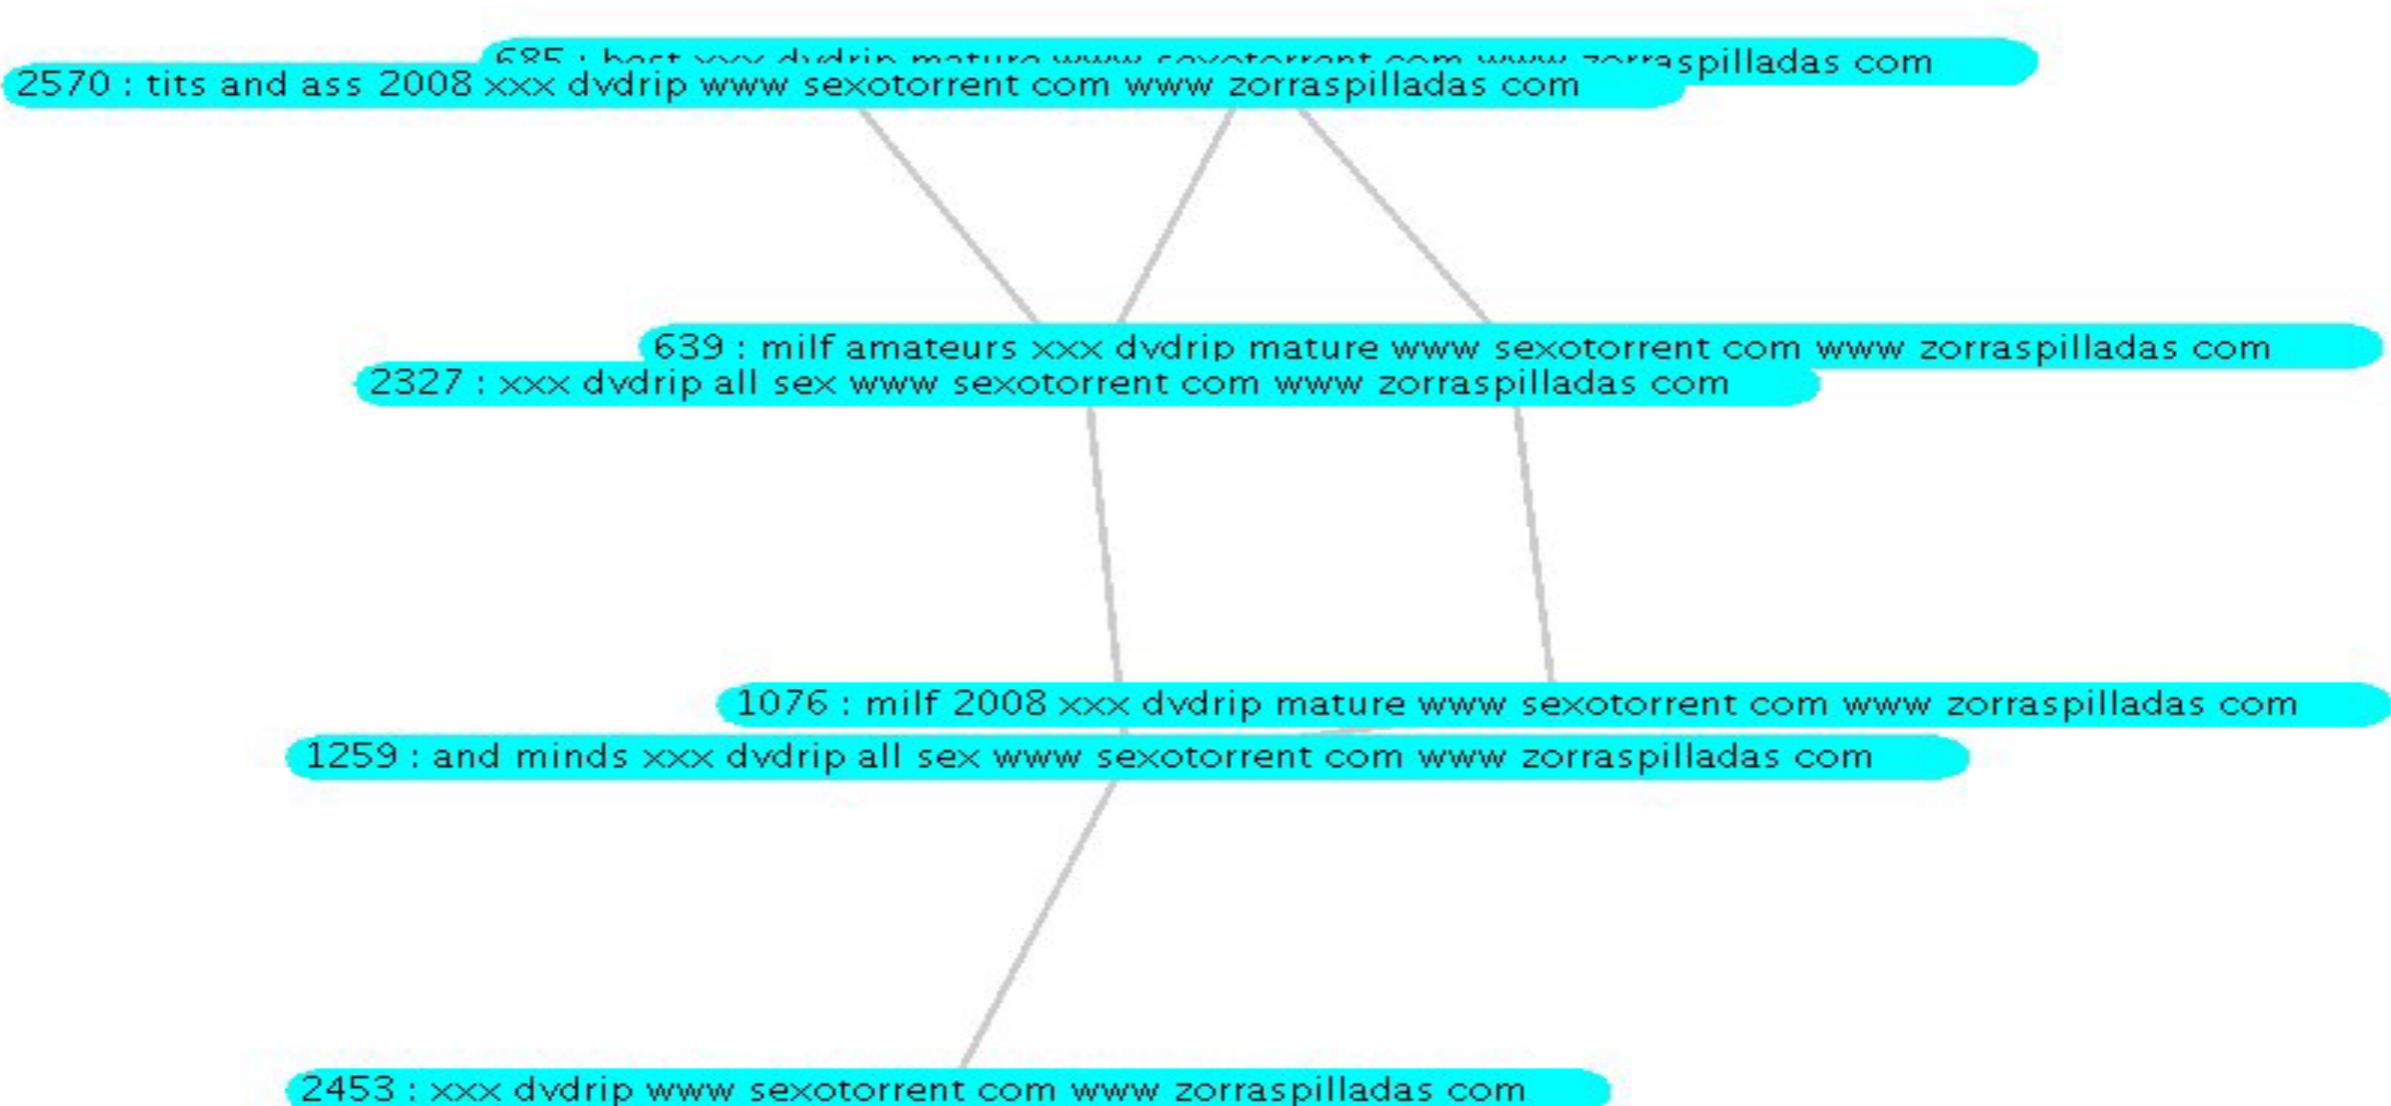
Détection de communautés

Structure+Contenu



Détection de communautés

Structure+Contenu

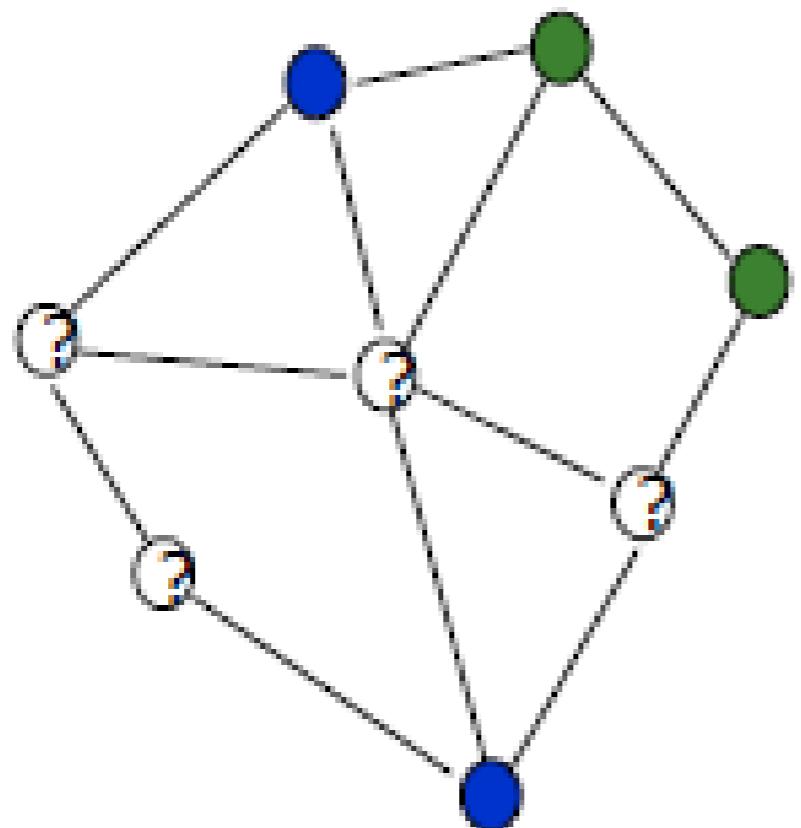


Détection de communautés

Structure+Contenu



Apprentissage supervisé



- Généraliser des étiquettes à un ensemble de nœuds d'un graphe
 - Ex: Vert = pédophilie, Bleu = Pas pédophilie
 - Identification des utilisateurs/fichiers pédophiles
- Utilisation de méthodes d'apprentissage semi-supervisée
 - Utilisation du contenu
 - Propagation des labels

Conclusion et pistes futures

- Travaux en cours (P2P) :
 - Détection Communauté d'intérêts
 - Identifier de nouveaux mots clés pédophiles
 - Analyse de la diffusion de fichiers
- Travaux en cours (généraux):
 - Prise en compte de données multi-relationnelles
 - Prise en compte de graphes N-partite

Questions ?