

Treillis en classification et fouille de données

Panorama de l'utilisation des treillis à Metz

Alain Gély
LITA, Université Paul Verlaine, Metz
gely@univ-metz.fr

*Journée des Treillis Clermontois
Clermont-Ferrand
3 Décembre 2009*

Organisation & thèmes de recherche

Université **P**aul **V**erlaine **M**etz

Laboratoire d'**I**nformatique **T**héorique et **A**ppliquée

Équipe Algorithmique et Optimisation

Thème "Fouille de données et extraction de connaissances"



Lydia Boudjeloud

- Visualisation de données
- Données évolutives
- Masses de données



François Brucker

<http://francois.brucker.perso.centrale-marseille.fr/>

- Classification
- Mathématiques discrètes
- Combinatoire



Alain Gély

<http://www.lita.univ-metz.fr/~gely/>

- Algorithmique
- Structures discrètes
- Treillis & représentations associées

collaborations sur un Contrat Plan Etat Région "Traitement et visualisation de grands ensembles de données"

Système de classes sur X

Famille \mathcal{F} d'ensembles tq
 $\{x\} \in \mathcal{F}$ quel que soit $x \in X$
 $X \in \mathcal{F}$.

Système de fermeture sur X

Famille \mathcal{F} d'ensembles tq
 $Y, Z \in \mathcal{F}$ implique $Y \cap Z \in \mathcal{F}$
 $X \in \mathcal{F}$.

quitte à ajouter les intersections manquantes, on peut toujours ramener un système de classes à un système de fermeture.

Système de classes sur X

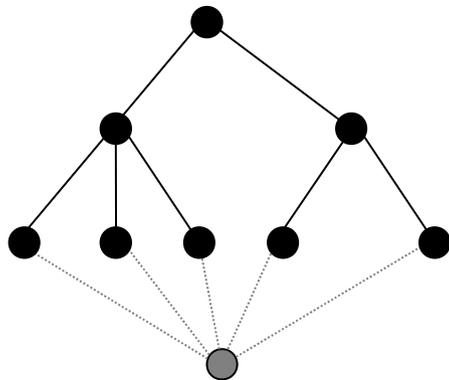
Famille \mathcal{F} d'ensembles tq
 $\{x\} \in \mathcal{F}$ quel que soit $x \in X$
 $X \in \mathcal{F}$.

Système de fermeture sur X

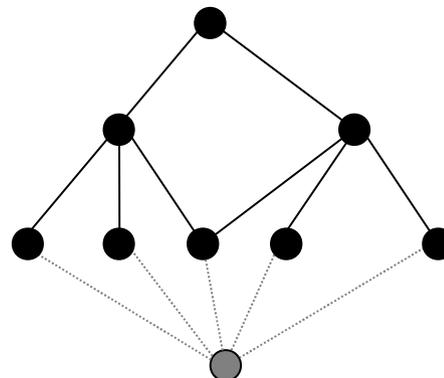
Famille \mathcal{F} d'ensembles tq
 $Y, Z \in \mathcal{F}$ implique $Y \cap Z \in \mathcal{F}$
 $X \in \mathcal{F}$.

En fonction des propriétés que l'on cherche à obtenir sur le système de classe, on aura différents types de systèmes de fermeture.

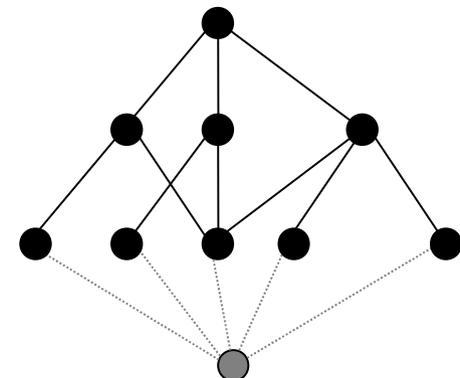
- Quasi Hiérarchies
- Pseudo Hiérarchies
- Hiérarchies
- ...



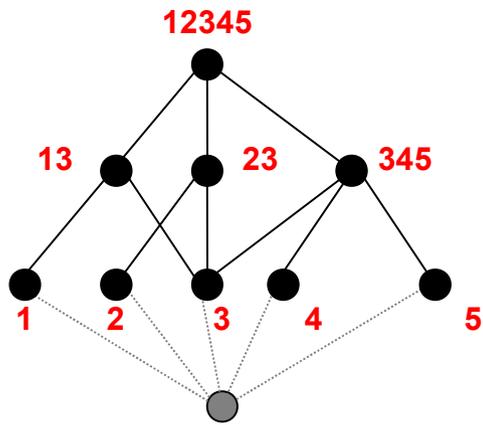
hiérarchie



Pseudo-hiérarchie



Quasi-hiérarchie



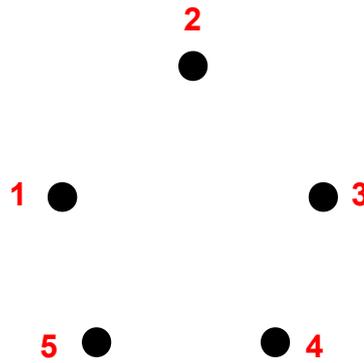
Quasi-hiérarchie

	1	2	3	4	5
1	0	2	1	2	2
2		0	1	2	2
3			0	1	1
4				0	1
5					0

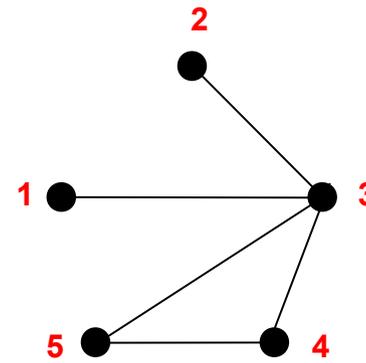
Matrice de dissimilarité

Les quasi-hiérarchies sont une frontière.

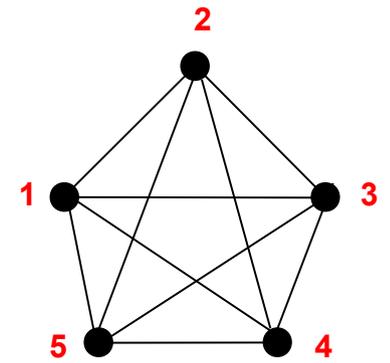
Correspondance entre **n'importe quel indice** et le système de classes, vu comme **famille de cliques maximales** de graphes seuils.



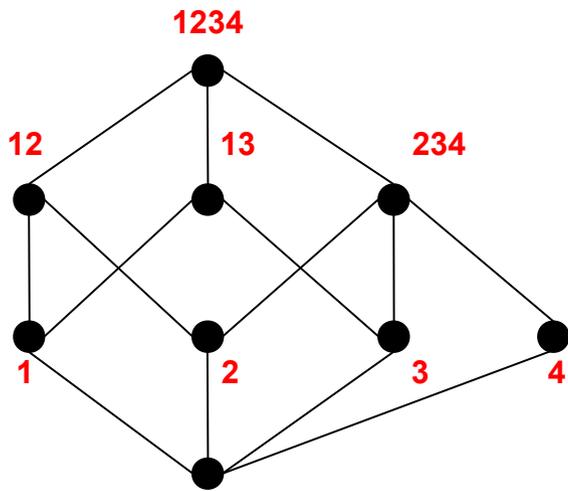
graphe seuil ≤ 0



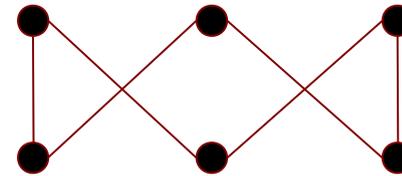
graphe seuil ≤ 1



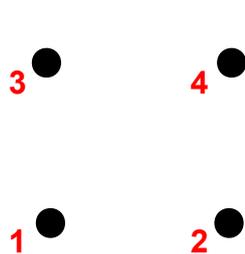
graphe seuil ≤ 2



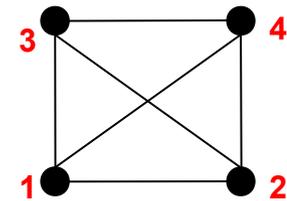
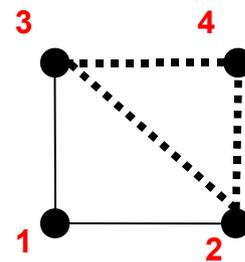
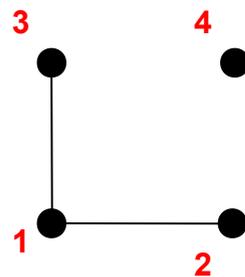
dans une **quasi-hiérarchie**, l'intersection de trois classes est égale à l'intersection de deux d'entre elles.



Couronne à 3 éléments
Configuration interdite



graphe seuil
 ≤ 0



graphe seuil
 $\leq \infty$

impossibilité de retrouver les classes

quasi-hiérarchie

*frontière indices / Cliques.
configuration interdite : 3-couronnes*

**système de classes
parcimonieux**

*Introduit par F. Brucker comme généralisation des arbres de
phylogénie*

pseudo-hiérarchie

*Diagramme de Hasse Planaire
(hypergraphes d'intervalles)*

hiérarchie

Arbres (emboîtement des classes)

Étude des systèmes de classes parcimonieux

- En bijection avec la classe des **treillis démantelables** atomiques définie par Rival en 74
- Configuration interdite : n-couronne
- chaque classe peut être définie par 2 éléments
- Propriétés d'élimination

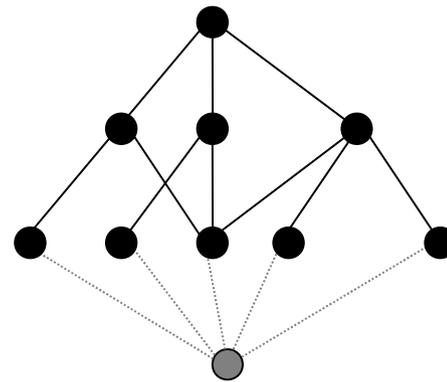
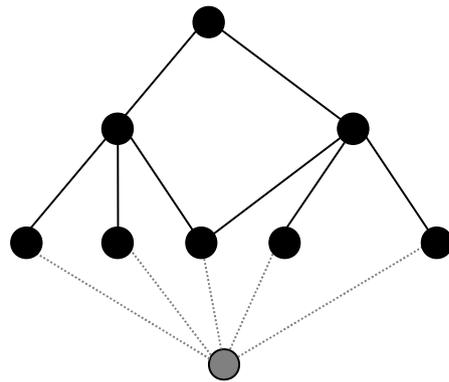
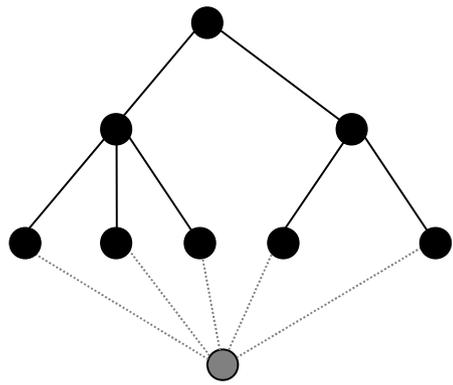
Aux précédentes journées treillis... (journées lorraines)

- Les systèmes de classes parcimonieux (alors appelés X-hyperarbres) sont les hyper-arbres stables par restrictions.
- Les hyper-arbres stables par restrictions sont en bijection avec les treillis démantelables.

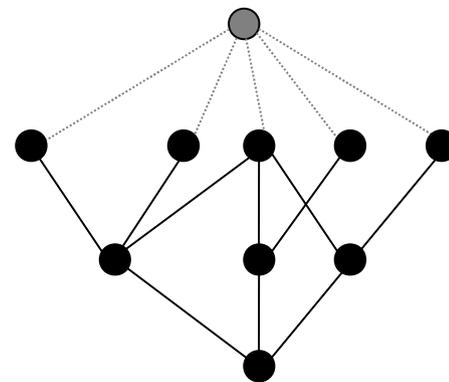
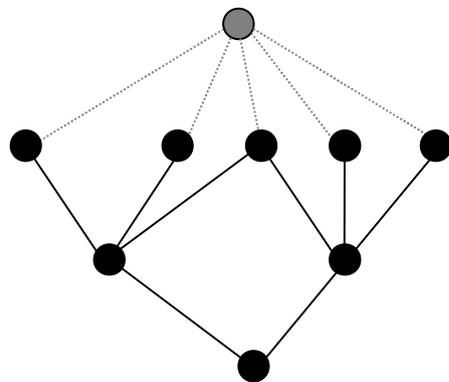
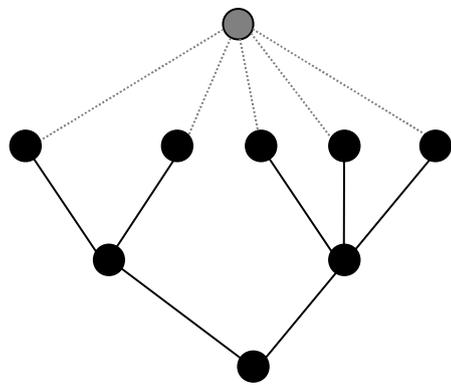
Conséquences

- Bonne propriétés pour la classification (on peut faire une classification identique sur une sous partie des espèces)
- Informations sur les interactions entre classes contenues dans l'ordre d'élimination (effeuillage)

... Mais (à l'issu des dernières journées), quelques inconnues sur les interactions graphes / treillis.

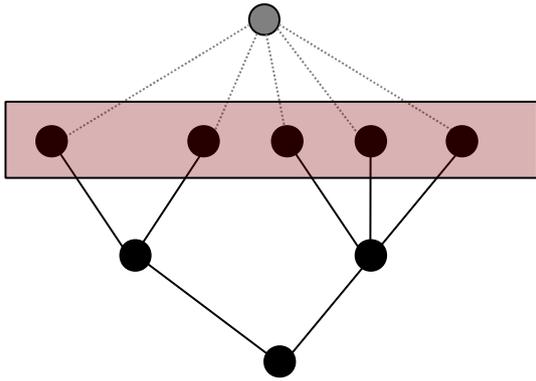


systemes de classes (atomiques)



Dual co-atomiques





-- idée --

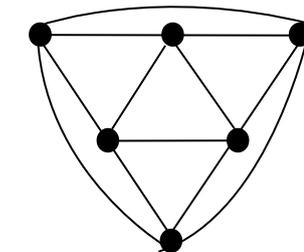
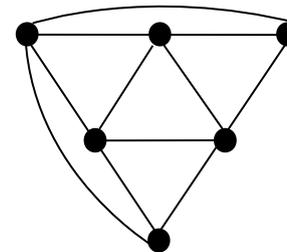
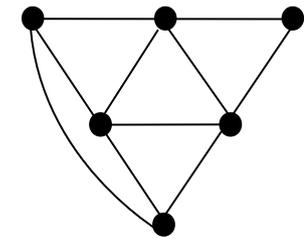
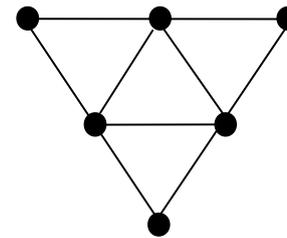
considérer que les co-atomes sont les cliques maximales d'un graphe.

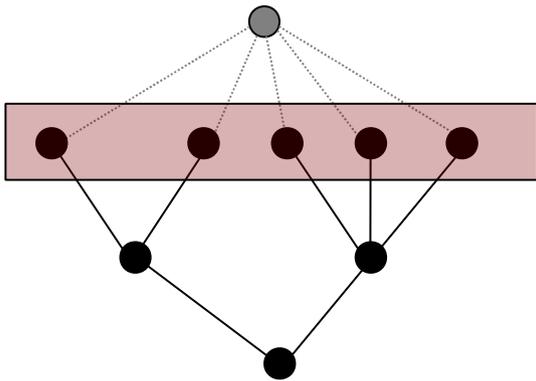
les quasi-hiérarchies

sont en bijection

avec les treillis des cliques maximales

d'un graphe ne possédant aucune des quatre graphes ci-contre comme sous graphe induit



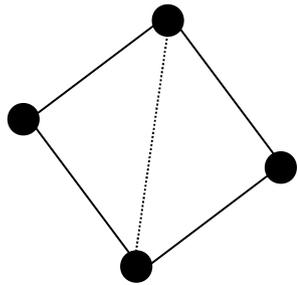


Et pour les systèmes de classes parcimonieux ?
(treillis démantelables co-atomique)

- Un treillis est démantelable ssi p il existe une séquence de n sous-treillis de T , $\emptyset = S_0 \subset \dots \subset S_n = T$ de sous-treillis de T tq $|S_i| = |S_{i-1}| + 1$ pour tout $i=1,2,\dots,n$
- i.e on peut aboutir à un treillis vidé de tous ses éléments en retirant, à chaque étape, un **élément doublement irréductible**.

parallèle avec les graphes...

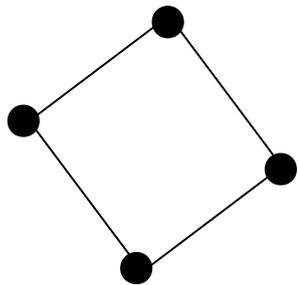
Dans les graphes triangulés, on peut aboutir à un graphe vidé de tous ses sommets en retirant, à chaque étape, **un sommet simplicial**.



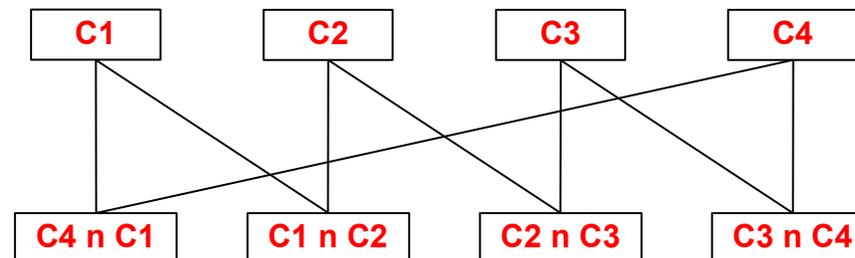
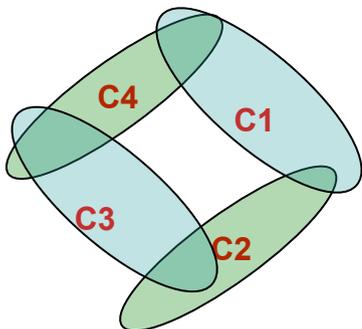
Graphes triangulés (cordés)

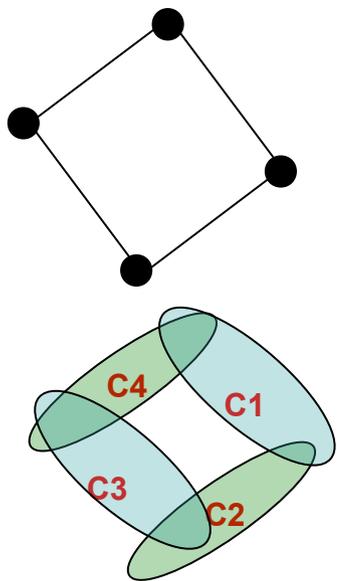
$G=(V,E)$ est un **graphe cordé** ssi tout cycle de sommets de longueur supérieure à 3 est cordé.

un sommet simplicial est un sommet dont le voisinage est une clique.

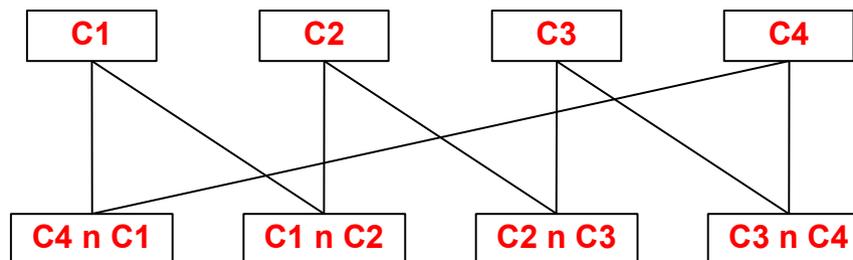


$G=(V,E)$ **graphe cordé** est une **condition nécessaire** à l'obtention d'un treillis des cliques maximales démantelable.

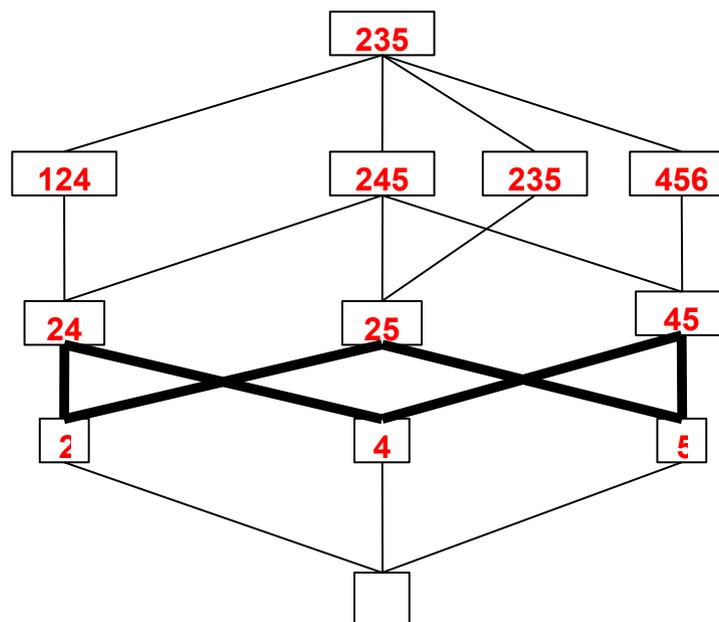
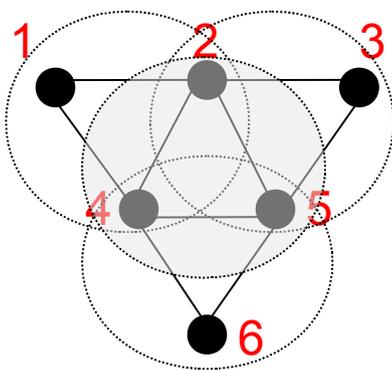




$G=(V,E)$ **graphe cordé**
est une **condition nécessaire** à l'obtention d'un treillis des cliques maximales démantelable.

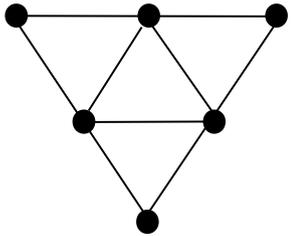


$G=(V,E)$ **graphe cordé**
n'est **pas** une **condition suffisante**

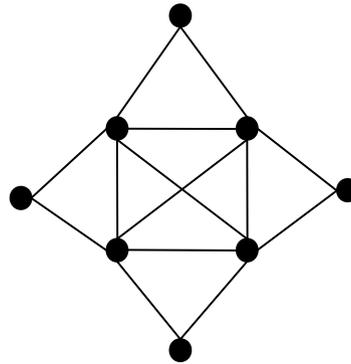


graphes fortement cordés \subset graphes cordés

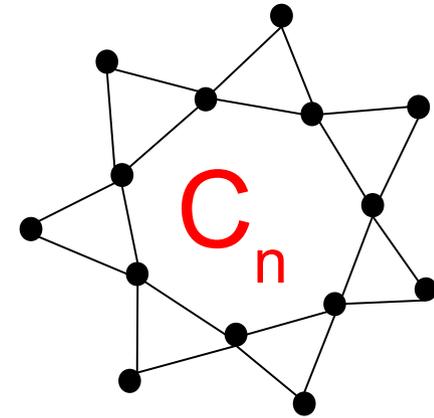
$G=(V,E)$ **graphe fortement cordé** (strongly chordal)
ssi G est **cordé** et **sans soleils induits**.



3-soleil



4-soleil



n-soleil

- $G=(V,E)$ **graphe fortement cordé** est caractérisé par
- l'existence d'un schéma d'**élimination fortement simplicial**
 - l'existence d'un schéma d'**élimination simple**.

Résultats.

- Les treillis démantelables co-atomiques sont en bijection avec les treillis des cliques maximales d'un graphe fortement cordé G .
- Une feuille, telle que définie dans les systèmes de classes parcimonieux, est un sommet simple de G , tels que définis par Farber en 83

Perspectives & axes de recherches.

- Transfert de connaissances graphes / treillis / classification
 - Visualisation du système de classes (treillis, arbre des cliques, ...)
 - caractérisation de graphes par leur treillis des cliques maximales.
- Plongements de données quelconques dans le modèle
 - propriétés du plongement
 - algorithmique efficace
- Applications sur données réelles

Merci
Questions ?