

# **CLUSTERING CONCEPTUEL À BASE DE MOTIFS LOCALEMENT OPTIMAUX**

## **ATELIER CLUCO, EGC 2015**

frederic.pennerath@centralesupelec.fr

Equipe IMS

Centrale-Supélec, campus de Metz

# Résumé

- Clustering conceptuel.

## Exemple de COBWEB (Fisher 87)

- Problèmes de sélection de motifs fréquents
- Les motifs localement optimaux (Pennerath 09)
- Limitation du modèle
- Redondance de motifs
- Les motifs  $\delta$ -localement optimaux

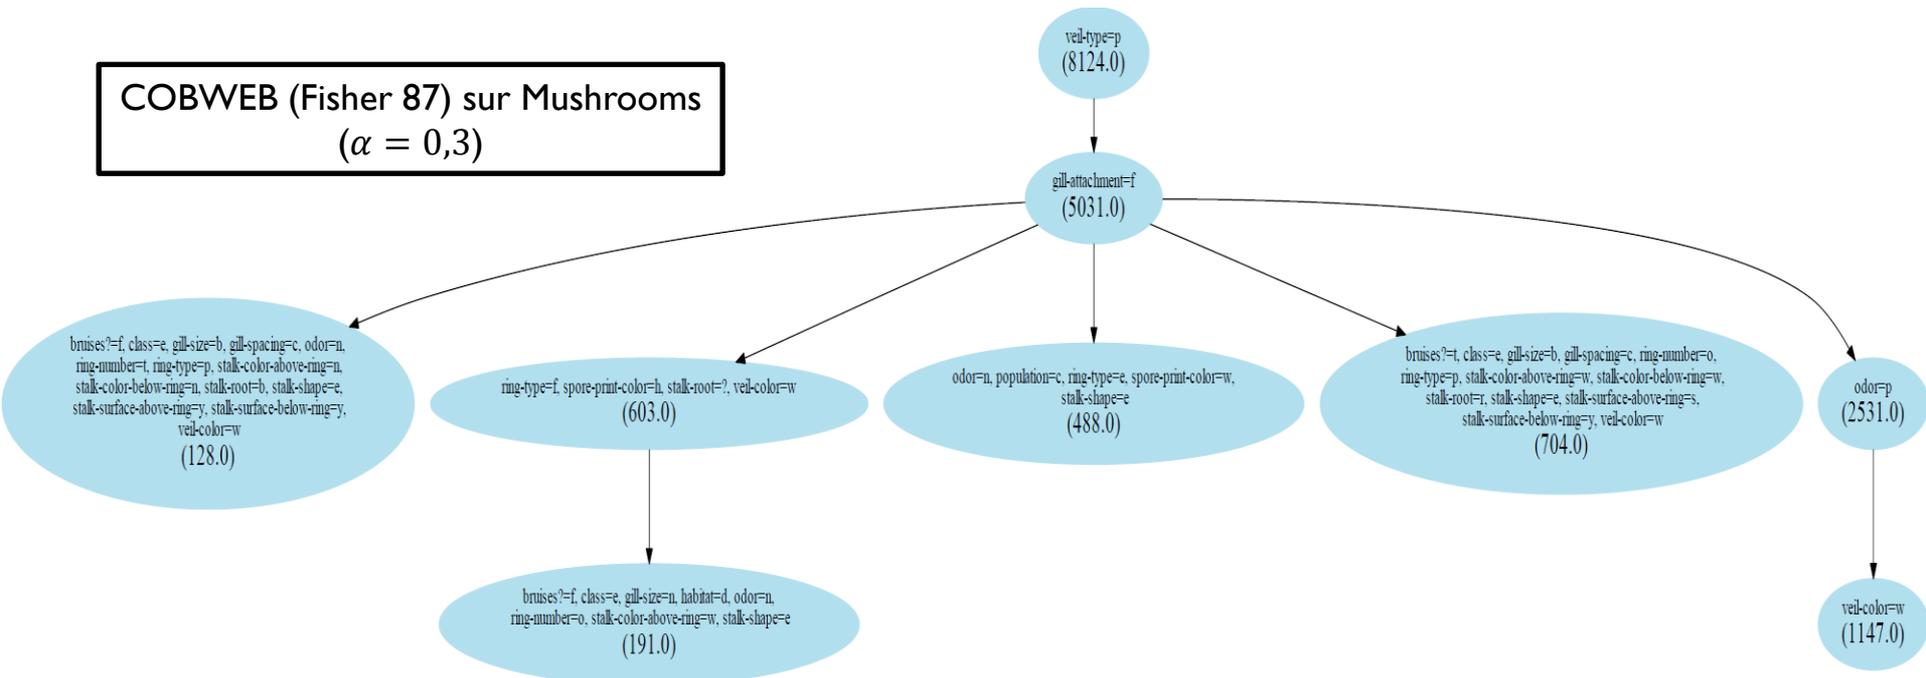
# Clustering conceptuel (symbolique)

Extraire de données une hiérarchie de concepts (intension, extension) avec :

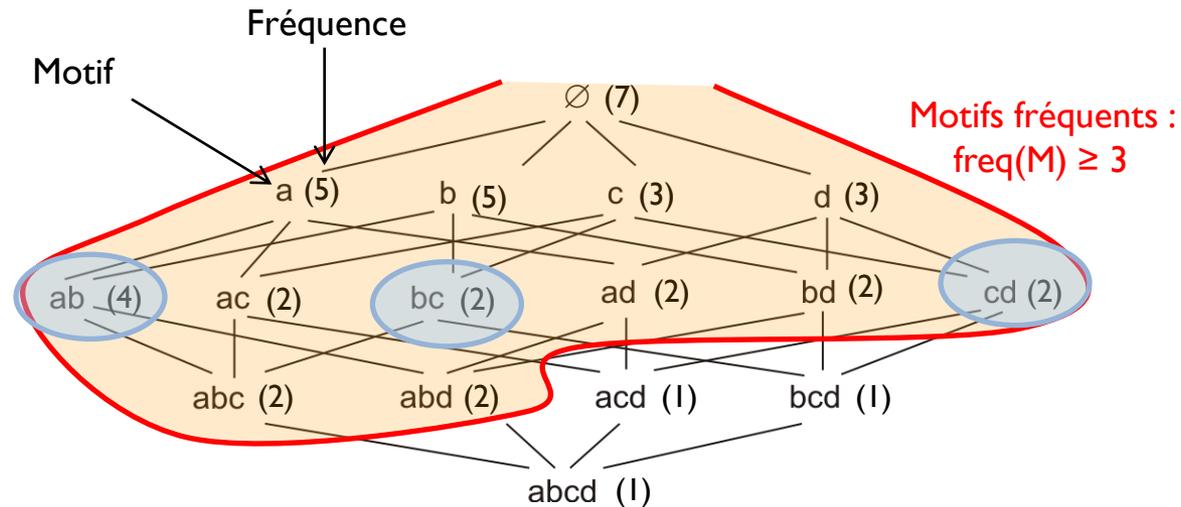
- Des concepts représentatifs des données → de grandes extensions
- Des concepts descriptifs des données → de grandes intensions

→ Problème de compromis

COBWEB (Fisher 87) sur Mushrooms  
( $\alpha = 0,3$ )



# Problèmes de sélection de motifs fréquents



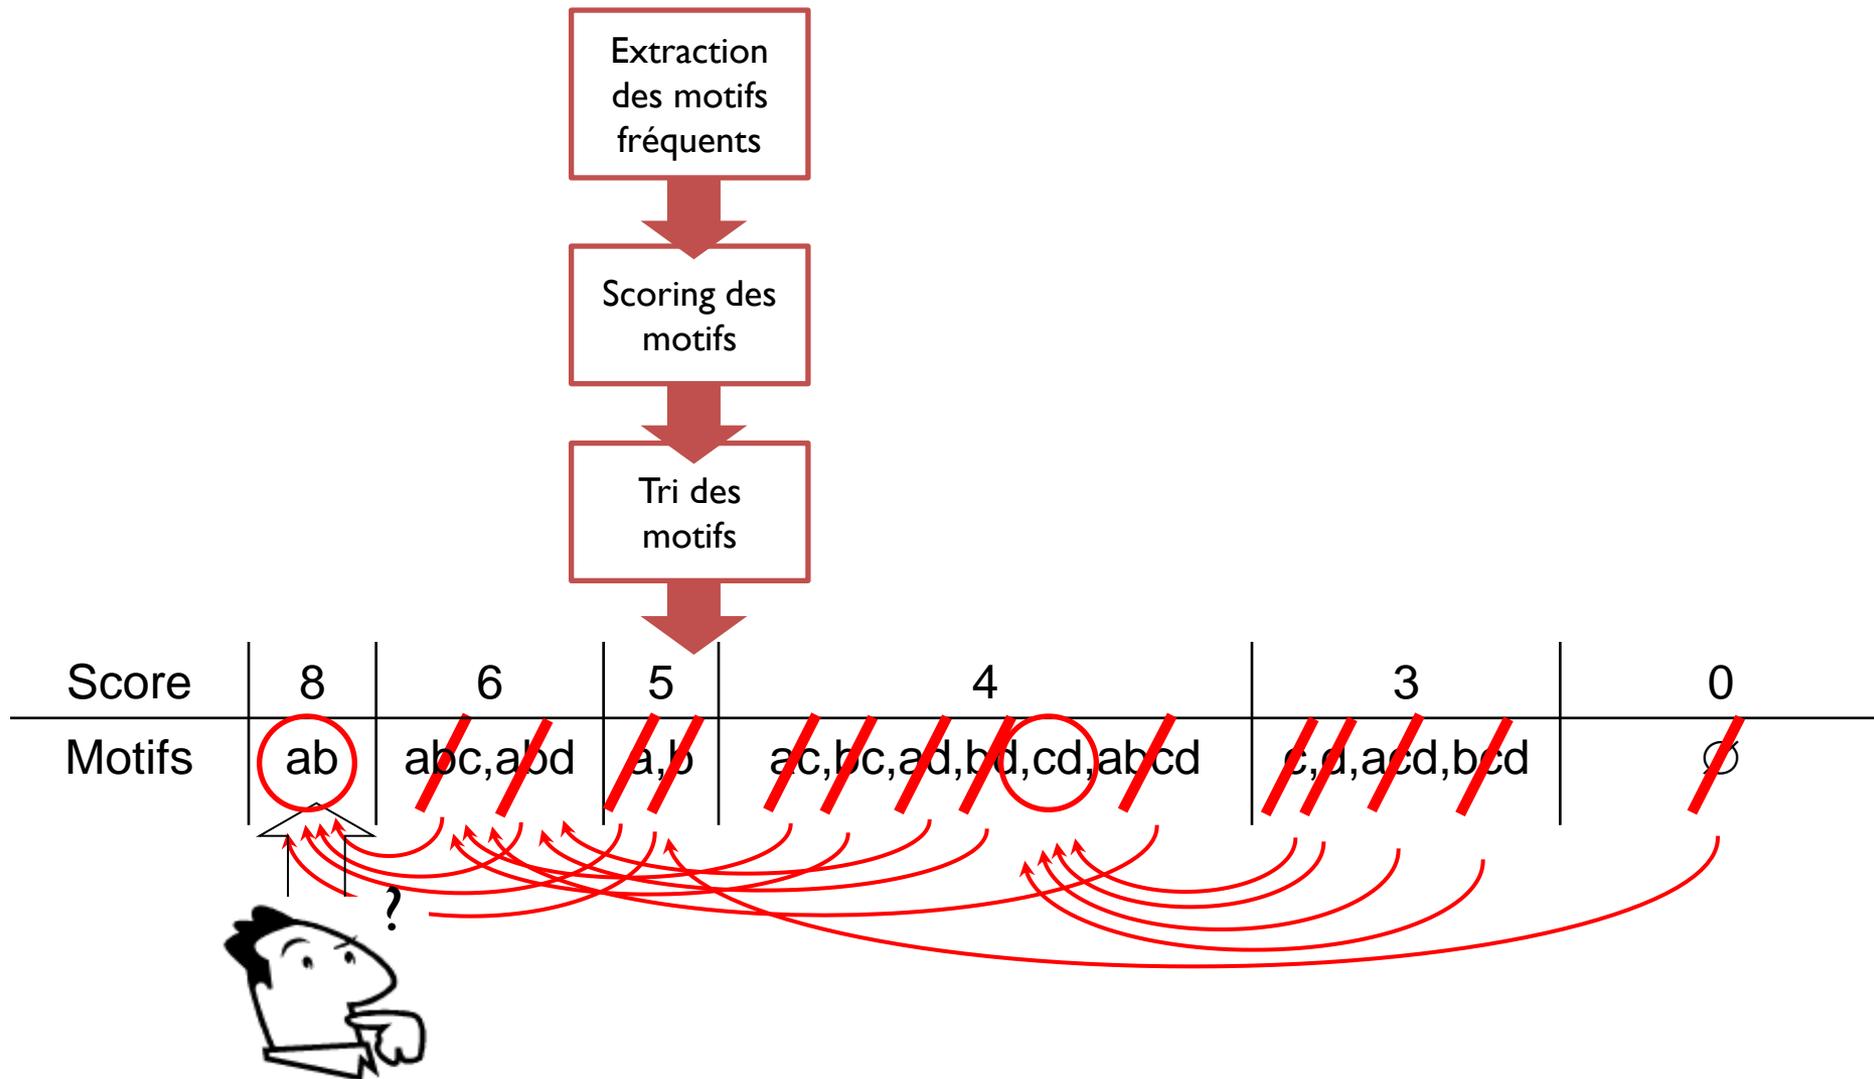
## Extraire un ensemble de motifs $\{M_i\}$ parmi les fréquents

- Peu nombreux
- Descriptifs  $\approx$  faible distance intra-classe
- Non redondants  $\approx$  forte distance inter-classe

## Nombreuses propositions :

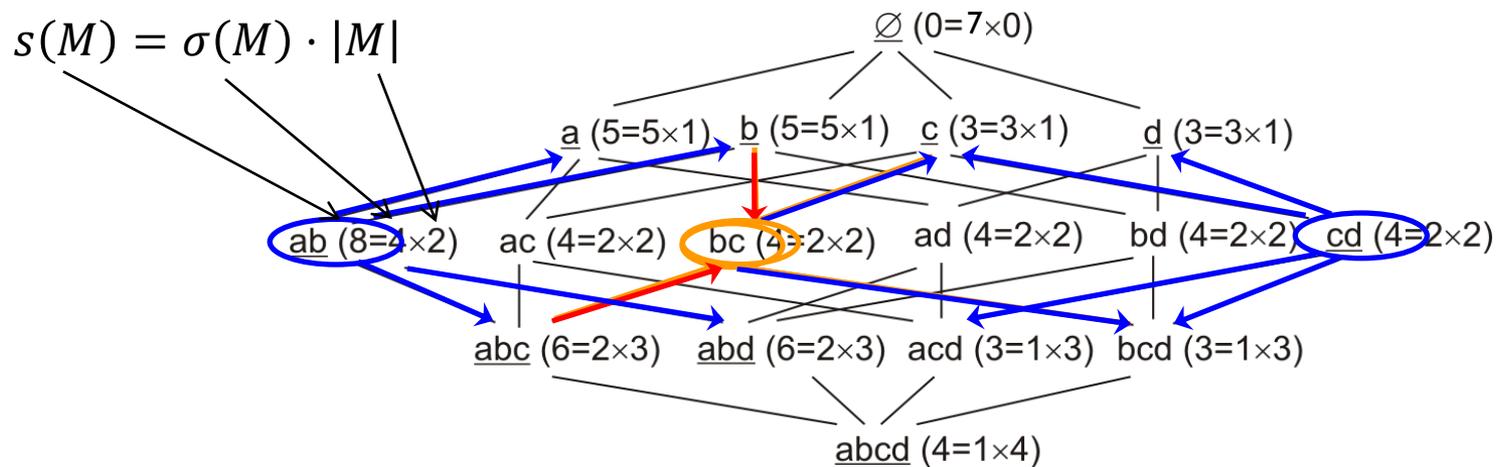
Mampaey11, Van Leeuwen11, Knobbe10, Tatti10, Pennerath09, Knobbe06, etc

# La sélection (naïve) de motifs par un expert



# Le modèle des motifs localement optimaux (MLOs)

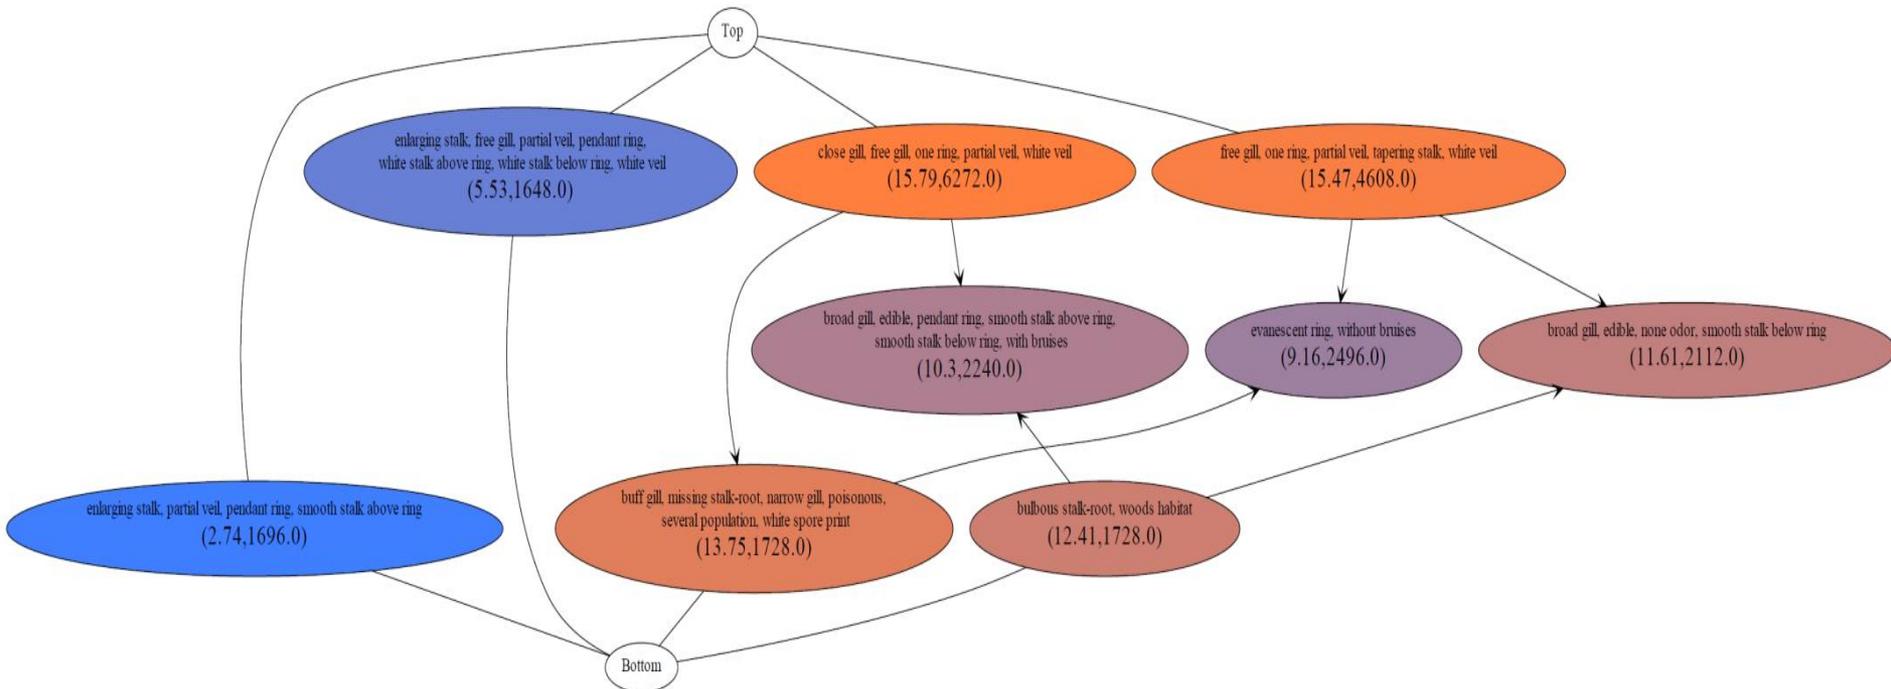
- **Ordre des motifs**  $(\mathcal{M}, \subseteq_{\mathcal{M}})$
- **Fonction de score**  $s : (\mathcal{M}, \subseteq_{\mathcal{M}}) \rightarrow (\mathcal{S}, \leq_{\mathcal{S}})$
- **Voisinage** d'un motif  $M$  : prédécesseurs et successeurs immédiats de  $M$
- $M'$  **domine**  $M$  si  $M'$  et  $M$  sont voisins et si  $s(M) <_{\mathcal{S}} s(M')$
- Un motif est **localement optimal** s'il n'est dominé par aucun motif.



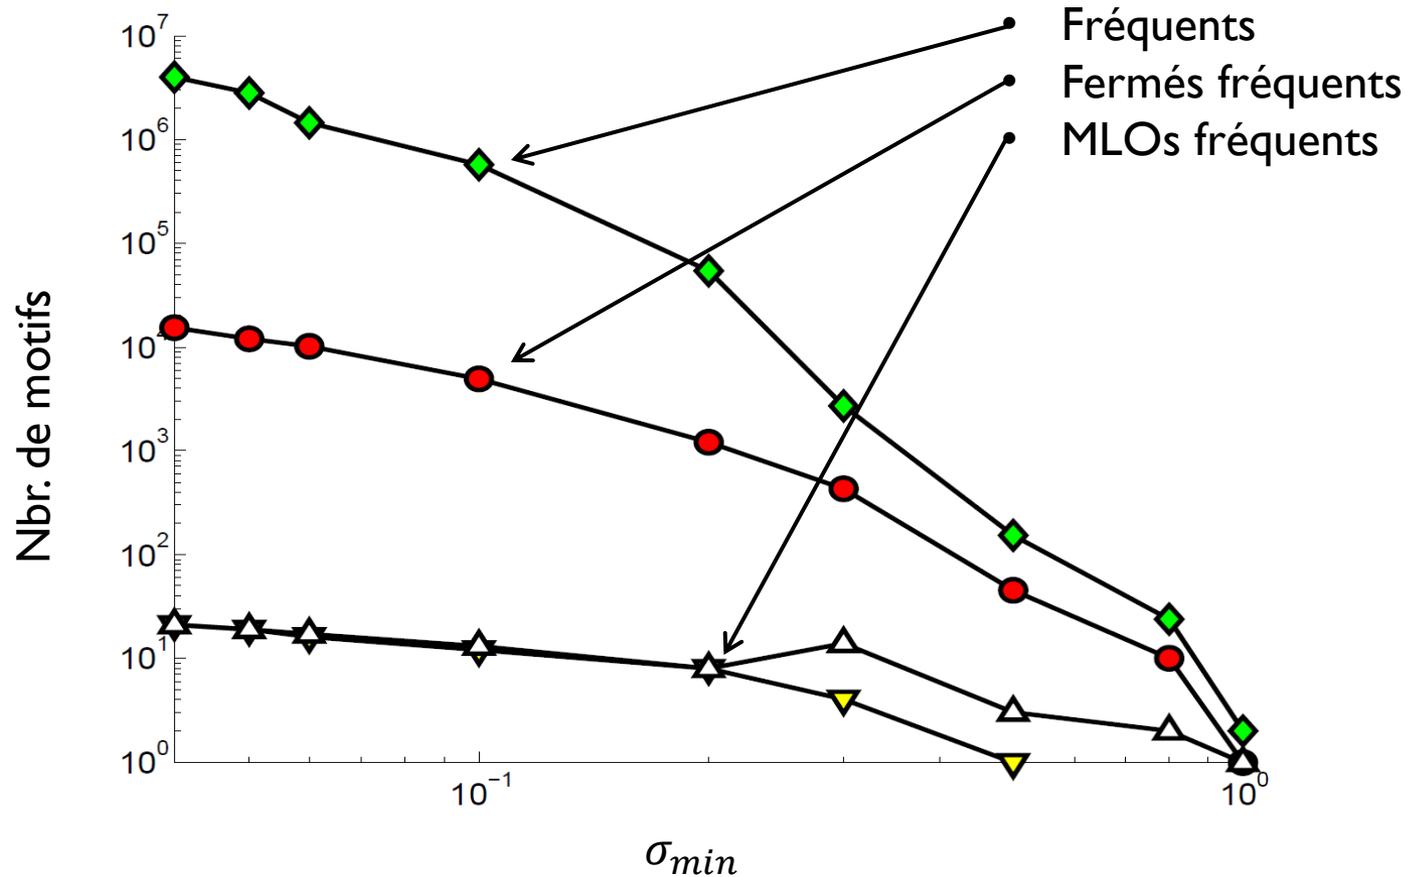
# Exemple de Mushrooms

Pour  $\sigma_{min} = 0,2$ :

- >53000 motifs fréquents
- >1200 motifs fermés fréquents
- 9 motifs localement optimaux fréquents pour  $s(M) = I(M) \cdot \sigma(M)$



# Exemple de Mushrooms

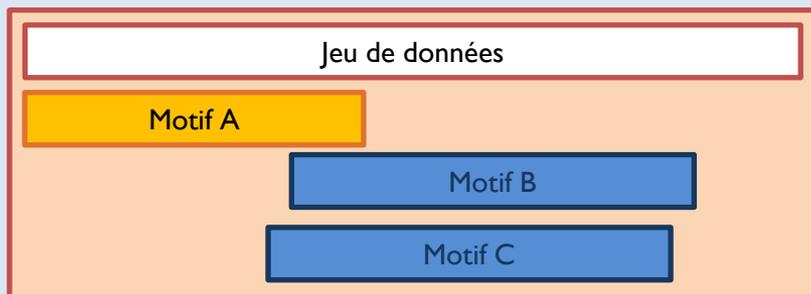


# Comment est définie la redondance entre motifs ?

## Redondance dans l'espace des données :

*Deux motifs sont redondants s'ils ont approximativement le même support*

*(i.e. ont un indice de Jaccard proche de 1).*



## Avantages :

- Indicateurs calculables facilement et rapidement
- Facile à justifier du point de vue des statistiques

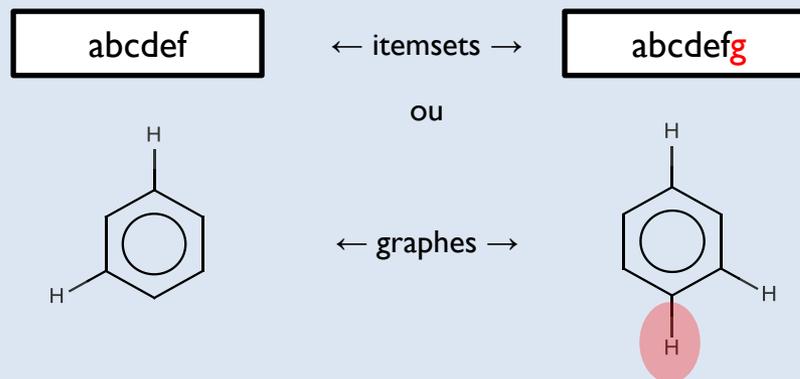
## Inconvénients :

- Aveugle aux connaissances du domaine
- Souvent hiérarchie de motifs horizontale (partition des données)

## Redondance dans l'espace des motifs :

*Deux motifs sont redondants s'ils sont structurellement semblables*

*(i.e. ont une faible distance d'édition)*



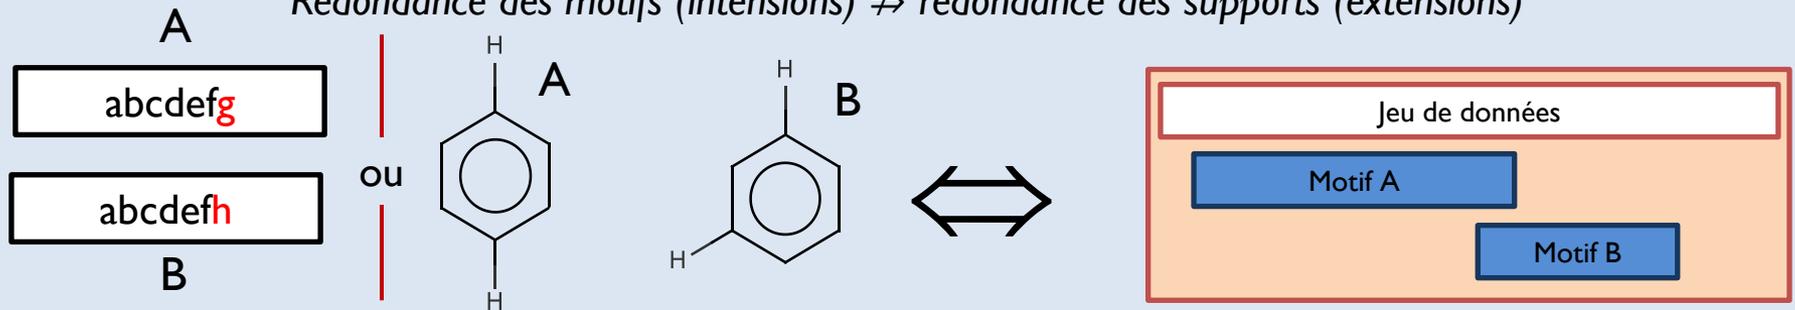
## Avantages :

- Agit dans le domaine d'interprétation de l'expert.
- La distance d'édition peut intégrer des connaissances du domaine.
- Compatible avec une hiérarchie verticale

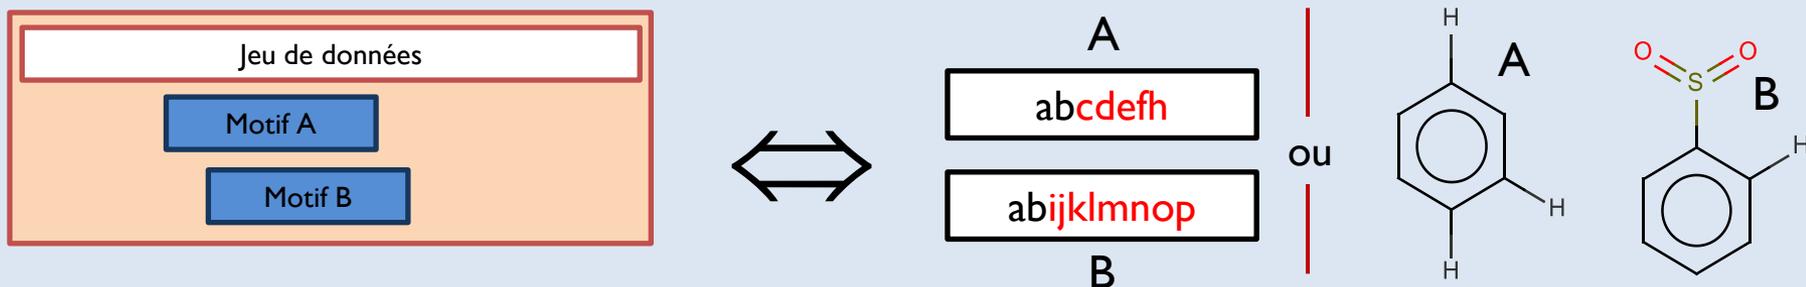
# Les deux formes de redondance sont-elles redondantes ?

Souvent mais pas toujours...

*Redondance des motifs (intensions)  $\nRightarrow$  redondance des supports (extensions)*



*Redondance des supports  $\nRightarrow$  redondance des motifs*



# Relation de $\delta$ -dominance

**Définition :** pour  $\delta \in [0,1]$

$M'$   **$\delta$ -domine**  $M$  si  $s(M') >_{\delta} s(M)$  et si  $M$  et  $M'$  sont redondants

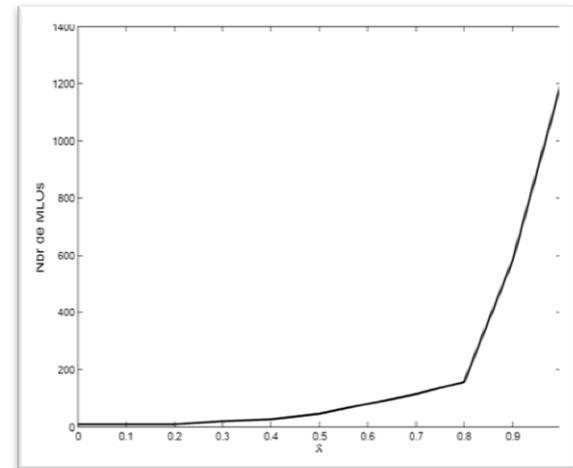
- dans l'espace des motifs, i.e.  $M$  et  $M'$  sont voisins
- dans l'espace des données, i.e.  $J(M_1, M_2) \stackrel{\text{def}}{=} J(\text{ext}(M_1), \text{ext}(M_2)) \geq \delta$

**Propriétés :**

- Si  $\delta = 0$ , les  $\delta$ -MLOs sont les MLOs
- Si  $\delta = 1$ , les  $\delta$ -MLOs sont les fermés
- Si  $\delta_1 \leq \delta_2$ ,  $\{ \delta_1\text{-MLOs} \} \subseteq \{ \delta_2\text{-MLOs} \}$

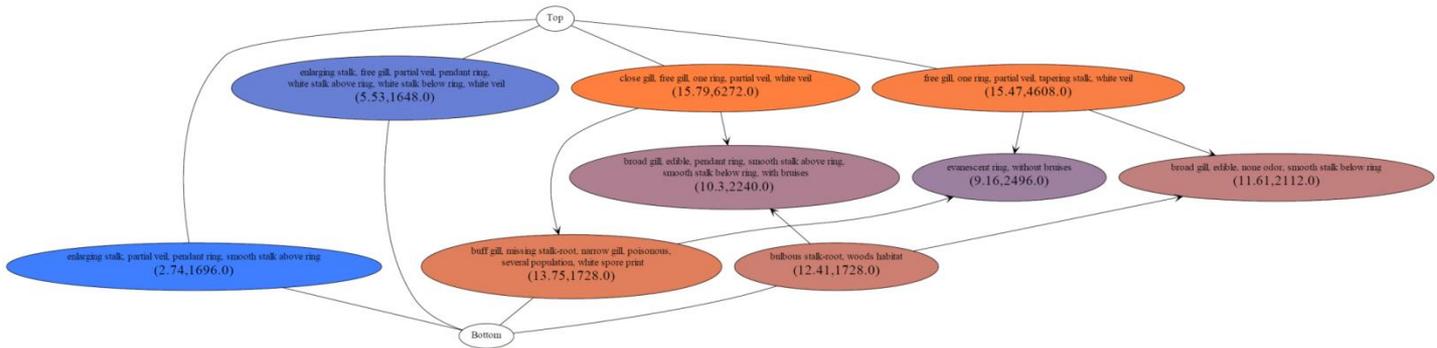
- Immédiat à prendre en compte :

$$J(M_1, M_2) = J(M_1, M_1 \cup \{i\}) = \frac{|\text{ext}(M_1) \cap \text{ext}(M_1 \cup \{i\})|}{|\text{ext}(M_1) \cup \text{ext}(M_1 \cup \{i\})|} = \frac{|\text{ext}(M_1 \cup \{i\})|}{|\text{ext}(M_1)|} = \frac{\sigma(M_2)}{\sigma(M_1)}$$

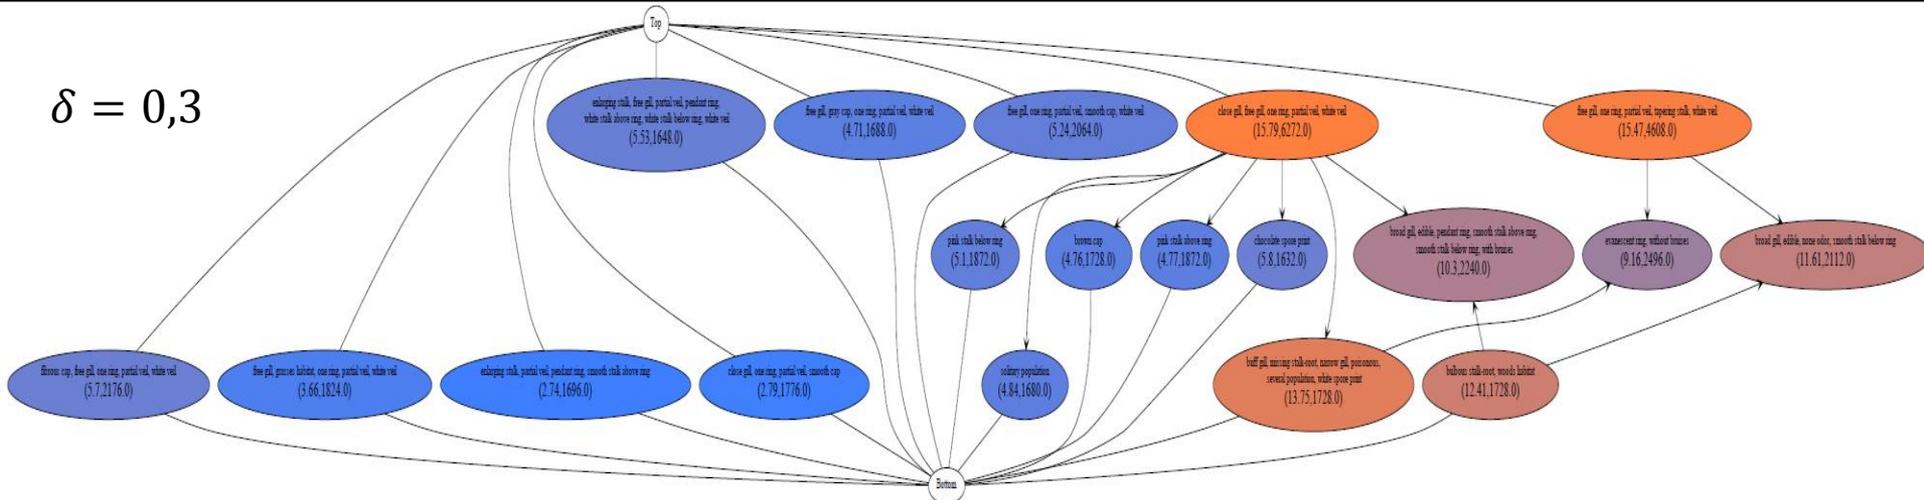


# $\delta$ -MLOs de Mushrooms ( $\sigma_{min} = 0,2$ )

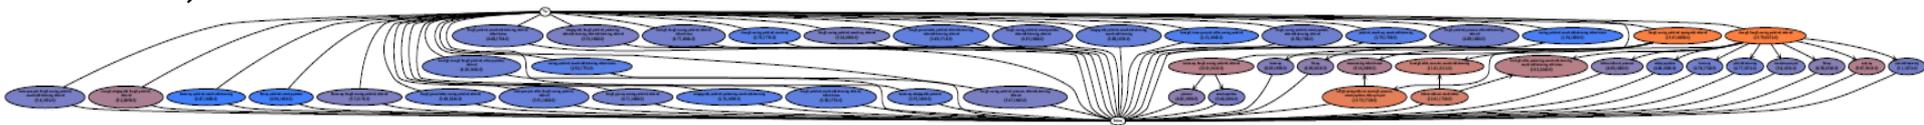
$\delta = 0,2$



$\delta = 0,3$



$\delta = 0,5$



# Conclusions

- $\delta$ -MLOs définissent un clustering conceptuel satisfaisant
  - Peu de motifs non redondants
  - Niveau de granularité modulable
  - Développement horizontal et vertical équilibré
- Avantage des  $\delta$ -MLOs par rapport à COBWEB et aux autres méthodes de sélection de motifs :
  - Prise en compte de la redondance dans l'espace des motifs
  - Prise en compte des connaissances métier (fonction de score, voisinage)
  - Algorithme exact sans heuristique
- Perspective : comparaison plus systématique avec COBWEB