

Inférence de dépendances fonctionnelles



Marc Plantevit

marc.plantevit@liris.cnrs.fr



liris.cnrs.fr/marc.plantevit/doku/doku.php?id=lif10



Inférence de dépendances

Notion d'inférence

- Concept fondamental pour la théorie des bases de données.
- C'est la déduction des contraintes qui sont **sémantiquement impliquées** par d'autres.
- On va donner un **algorithme** (un calcul **symbolique**) qui permet de décider *effectivement* de cette implication **logique**.
- L'algorithme est un processus qui manipule des symboles, il s'appuie uniquement sur la *syntaxe* des dépendances. On vérifiera que cet algorithme est :
 - **correct** : toutes les déductions syntaxiques sont bien sémantiquement valides ;
 - **complet** : toutes les déductions sémantiquement valides peuvent bien être syntaxiquement déduites.



Outline

1 Inférence des dépendances fonctionnelles



Implication logique des dépendances fonctionnelles

Définition

Soit F un ensemble de DF sur un schéma de relation R et f une DF sur R . On surcharge \models pour un **ensemble** de DFs :

$$r \models F \text{ ssi } \forall f \in F. r \models f$$

F implique logiquement (sémantiquement) f , noté

$$F \models f \text{ ssi } \forall r. r \models F \Rightarrow r \models f$$

Exemple

Soit le schéma $Etudiant(Num, Nom, Ville, Region, CP)$ et l'ensemble de dépendances $F = \{f_1 = Num \rightarrow Nom, Ville, Region, f_2 = Ville, Region \rightarrow CP\}$. On peut déduire les DFs suivantes :

- $f'_1 = Num \rightarrow Nom, Ville$
- $f'_2 = Num \rightarrow CP$



Implication logique des dépendances fonctionnelles

En utilisant la sémantique des dépendances fonctionnelles, prouver qu'effectivement $F \models f'_1$ et $F \models f'_2$

- Difficile de prouver que chaque intuition est correcte.
- Comment s'assurer que l'énumération $\{f \mid F \models f\}$ est exhaustive ?
- On va donner un algorithme qui le fait.



Règles et système d'inférences

- Une **règle d'inférence** est une expression de la forme

$$\frac{f_0 \quad \dots \quad f_n}{f}$$

- Un **système d'inférence** est un ensemble de règles d'inférence.
- Une preuve de f à partir de F notée $F \vdash f$ est une *séquence* (f_0, \dots, f_n) de DFs telle que $f_n = f$ et $\forall i \in [0..n], :$
 - soit $f_i \in F$;
 - soit f_i est la conséquence d'une règle dont toutes les prémisses $f_0 \dots f_p$ apparaissent avant f_i dans la séquence.

Liens avec LIF11

Ce sont bien **les même notions** que celles des systèmes de déduction \mathcal{G} et \mathcal{LK} . Pour les preuves formelles, on pourra utiliser le même formalisme des arbres de preuves.



Système d'Armstrong

Système d'inférence d'Armstrong

Soit F un ensemble de DF sur un schéma de relation R . Les règles d'inférence suivantes sont appelées *système d'Armstrong*

- **Réflexivité**

$$\frac{Y \subseteq X}{X \rightarrow Y}$$

- **Augmentation**

$$\frac{X \rightarrow Y}{WX \rightarrow WY}$$

- **Transitivité**

$$\frac{X \rightarrow Y \quad Y \rightarrow Z}{X \rightarrow Z}$$



Propriétés du système d'Armstrong

Correction et complétude

- Il est **correct** : $F \vdash f \Rightarrow F \models f$
- Il est **complet** : $F \models f \Rightarrow F \vdash f$

$$F \models \alpha \Leftrightarrow F \vdash \alpha$$

Exemple

Considérons l'ensemble $\Sigma = \{A \rightarrow C, B \rightarrow C, CD \rightarrow E\}$ de DFs sur $\{A, B, C, D, E\}$. Montrons que $\Sigma \vdash AD \rightarrow E$

$$\frac{\frac{\frac{A \rightarrow B \quad B \rightarrow C}{A \rightarrow C}}{AD \rightarrow CD} \quad CD \rightarrow E}{AD \rightarrow E}$$

Par complétude, on a montré que $\Sigma \models AD \rightarrow E$.



Autres règles

- Décomposition

$$\frac{X \rightarrow YZ}{X \rightarrow Y}$$

- Composition

$$\frac{X \rightarrow Y \quad X \rightarrow Z}{X \rightarrow YZ}$$

- Pseudo-transitivité

$$\frac{X \rightarrow Y \quad WY \rightarrow Z}{WX \rightarrow Z}$$

Prouver que ces règles sont valides et qu'on peut les ajouter au système d'Armstrong

Exercice

Soit l'ensemble F de DF suivant sur le schéma $R = ABCDEFG$:

- $A \rightarrow B$
- $A \rightarrow C$
- $A \rightarrow D$
- $CD \rightarrow E$
- $BE \rightarrow F$
- $ABE \rightarrow G$
- $EG \rightarrow ABD$
- $FG \rightarrow AE$
- Démontrer que DF $F \models A \rightarrow F$.
- Démontrer que DF $F \models A \rightarrow G$.



Problème d'inférence de DF

Le système d'Armstrong permet de systématiser la recherche de toutes les DF impliquées par d'autres DF.

Problème d'inférence des DF

Soit F un ensemble de DF, et f une DF, a-t-on $F \models f$?

- La résolution du problème d'inférence est "facile" pour les DF,
- linéaire en la taille de F et de f .
- Le concept fondamental utilisé dans cet algorithme est celui de **fermeture**.

Fermeture d'un ensemble de DFs

Soit F un ensemble de DF, on note F^+ la **fermeture de F** , l'ensemble de toutes les Dfs logiquement impliquées par F :

$$F^+ = \{f \mid F \models f\}$$



Fermeture d'un ensemble d'attributs

Fermeture d'un ensemble d'attributs

X est un ensemble d'attribut et F un ensemble de DF, on note X^+ la **fermeture de X par rapport à F** l'ensemble de tous les attributs qu'on peut "déduire" de X par des dépendances fonctionnelles :

$$X^+ = \{A \mid F \models X \rightarrow A\}$$

D'après la définition de la fermeture de F , on a de façon équivalente :

$$X^+ = \{A \mid X \rightarrow A \in F^+\}$$

Il faut aussi tenir compte de *toutes* les DFs qui qui sont dérivables à partir de F .

Définition alternative de la notion de clé

- une clé de R est un ensemble $X \subseteq R$ tels que $R : X \rightarrow R$
- X est clé d'un schéma R ssi $X^+ = R$

Lemme

Soient F un ensemble de DF et $X \rightarrow Y$ une DF :

$$F \models X \rightarrow Y \text{ ssi } Y \subseteq X^+$$

- Ainsi, pour tester si on a $F \models X \rightarrow Y$, on calcule X^+ et on vérifie si $Y \subseteq X^+$
- On va utiliser un algorithme pour calculer simplement X^+
- On obtient ainsi un algorithme pour décide de l'implication logique des DFs.



Algorithme : fermeture d'un ensemble d'attributs

Data: F un ensemble de DF, X un ensemble d'attributs.

Result: X^+ , la fermeture de X par F .

$unused := F$

$closure := X$

repeat

$closure' := closure$

if $W \rightarrow Z \in unused$ and $W \subseteq closure$ **then**

$unused := unused - \{W \rightarrow Z\}$

$closure := closure \cup Z$

end

until $closure' = closure$;

retourner $closure$

- L'algorithme permet de vérifier si un ensemble de DF implique logiquement une dépendance d'après le lemme vu avant.
- Pour tester l'implication d'un *ensemble de dépendances*, il suffit de tester l'implication de *chaque* dépendance.

Combien de fois (au plus) teste-t-on $W \subseteq closure$
en fonction de $|F| = n$?

Un algorithme linéaire

Amélioration pour obtenir un temps linéaire en la taille de $|F|$ *faire en sorte de ne se servir d'une DF qu'une seule fois* quand c'est nécessaire :

- Pour chaque $X \rightarrow Y \in F$ non utilisée, il faut stocker le *nombre* d'attributs de X non encore dans *closure*.
- Pour le faire efficacement, il faut maintenir à jour une liste pour chaque attribut A des DFs de F non utilisées pour lesquelles A apparaît en partie gauche.



Algorithme : fermeture linéaire

```

for  $W \rightarrow Z \in F$  do
  |  $count[W \rightarrow Z] := |W|$ 
  | for  $A \in W$  do
  | |  $list[A] := list[A] \cup W \rightarrow Z$ 
  | end
end
 $closure := X, update := X$ 
while  $update \neq \emptyset$  do
  |  $update := update \setminus \{A\}$ 
  | for  $W \rightarrow Z \in list[A]$  do
  | |  $count[W \rightarrow Z] := count[W \rightarrow Z] - 1$ 
  | | if  $count[W \rightarrow Z] = 0$  then
  | | |  $update := update \cup (Z \setminus closure)$ 
  | | |  $closure := closure \cup Z$ 
  | | end
  | end
end
return  $closure$ 

```

Exercice

Avec l'ensemble de de DFs donné précédemment :

- Démontrer que $F \models A \rightarrow F$ (avec fermeture).
- Démontrer que $F \models A \rightarrow G$ (avec fermeture).
- Démontrez que BEF n'est pas une clé de R
- Démontrez que $CDE \rightarrow A$ n'est pas impliquée par F

Fin du troisième cours.