

LIF10 – FONDEMENTS DES BASES DE DONNÉES

TD3 – fermeture d'un ensemble d'attributs

Licence informatique – Automne 2014–2015

Les questions marquées du symbole (†) sont à préparer pour la séance

Algorithme 1: fermeture d'un ensemble d'attributs par des dépendances fonctionnelles

Data : Σ un ensemble de DF, X un ensemble d'attributs.
Result : X^+ , la fermeture de X par Σ .

```
1 unused :=  $\Sigma$ 
2 closure :=  $X$ 
3 repeat
4   closure' := closure;
5   if  $W \rightarrow Z \in \textit{unused}$  and  $W \subseteq \textit{closure}$  then
6     unused := unused -  $\{W \rightarrow Z\}$ ;
7     closure := closure  $\cup$   $Z$ ;
8 until closure' = closure;
9 return closure;
```

Exercice 1 : inférence de dépendances (†)

Soit Σ l'ensemble des dépendances suivantes

| | |
|--------------------|--------------------|
| $BC \rightarrow A$ | $D \rightarrow BE$ |
| $AC \rightarrow B$ | $B \rightarrow DE$ |
| $AE \rightarrow C$ | $C \rightarrow E$ |

- (†) En utilisant les règles le système d'Armstrong augmenté des règles de composition et décomposition, prouver que les DF suivantes appartiennent à $\Sigma^+ = \{f \mid \Sigma \models f\}$:
 - (†) $AD \rightarrow C$
 - (†) $AB \rightarrow C$
 - (†) $AE \rightarrow BD$
 - $AC \rightarrow D$
 - $CD \rightarrow A$
- Même question en calculant la fermeture des parties gauches à partir de l'algorithme de fermeture.

Exercice 2 : correction de l'algorithme (†)

On rappelle qu'une preuve de $X \rightarrow Y$ à partir de Σ notée $\Sigma \vdash X \rightarrow Y$ est une *séquence* $\langle f_0, \dots, f_p \rangle$ de DFs telle que $f_p = X \rightarrow Y$ et $\forall i \in [0..p]$ on a soit $f_i \in \Sigma$, soit f_i est la conséquence de l'application d'une des règles d'Armstrong dont toutes les prémisses $f_0 \dots f_p$ apparaissent avant f_i dans la séquence. On donne le lemme

$$\Sigma \vdash X \rightarrow Y \text{ ssi } Y \subseteq X^*$$

Cet exercice a pour objectif de montrer que l'algorithme donné calcule bien $X^* = \{A \mid \Sigma \vdash X \rightarrow A\}$ à partir de X et Σ donnés. Pour cela, on considère la trace de l'algorithme définie comme une séquence $\langle X_0 \dots X_n \rangle$ de longueur maximale telle que $X_0 = X$, $X_i \subset X_{i+1}$ et $X_{i+1} = X_i \cup Z$ avec $W \rightarrow Z \in \Sigma$ et $W \subseteq X_i$. Notons que l'on fait abstraction du maintien de *unused* et *closure'* par soucis de simplification.

1. (†) Montrer par récurrence sur la longueur de la trace que $X_n \subseteq X^*$. Pour l'étape de récurrence $X_i \subseteq X^*$, pour $A \in X_{i+1}$ on considèrera les cas $A \in X_i$ ou $A \notin X_i$ en on utilisera le lemme.
2. Conclure que $X_n \subseteq \{A \mid \Sigma \models X \rightarrow A\}$.
3. Prouver par induction que $X \subseteq Y$ implique $X_n \subseteq Y_n$.
4. Prouver par induction sur la longueur d'une preuve de $\Sigma \vdash X \rightarrow Y$ que $X^* \subseteq X_n$. Pour l'induction on procède cas par cas pour chaque règle d'Armstrong (utiliser la proposition précédente).
5. Conclure sur la correction de l'algorithme.

Exercice 3 : fermeture algébrique

En algèbre abstraite on appelle fermeture une application $\phi : \wp(E) \rightarrow \wp(E)$ qui soit :

- *extensive* $X \subseteq \phi(X)$
- *croissante* $X \subseteq Y \Rightarrow \phi(X) \subseteq \phi(Y)$
- *idempotente* $\phi(\phi(X)) = \phi(X)$

1. Justifier que la fermeture X^+ est bien nommée. On utilisera la correction de l'algorithme.
2. En vous appuyant sur les propriétés précédentes calculer l'ensemble des fermés pour l'ensemble des dépendances Σ défini dans l'exercice 1, i.e., éviter d'énumérer des éléments « inutiles » parmi les $2^{|ABCDE|}$ solutions possibles.

Corrections

Solution de l'exercice 1

$$1. \quad 1. \quad \frac{\frac{D \rightarrow BE}{AD \rightarrow ABE} \text{ aug.} \quad \frac{AE \subseteq ABE}{ABE \rightarrow AE} \text{ refl.}}{AD \rightarrow AE} \text{ trans.} \quad \frac{AD \rightarrow AE \quad AE \rightarrow C}{AD \rightarrow C} \text{ trans.}$$

2. $AB \rightarrow C$

$B \rightarrow DE$ donc $AB \rightarrow ADE$ par augmentation

$AB \rightarrow AE$ par décomposition

$AB \rightarrow C$ puisque $AE \rightarrow C$ par transitivité

3. $AE \rightarrow BD$

$AE \rightarrow C$ donc $AE \rightarrow AC$ par augmentation

$AC \rightarrow B$ donc $AE \rightarrow B$ par transitivité

$B \rightarrow DE$ donc $B \rightarrow D$ par décomposition

On en déduit $AE \rightarrow D$ par transitivité

Par composition, on a $AE \rightarrow BD$.

4. $AC \rightarrow D$

$B \rightarrow DE$ donc $B \rightarrow D$ par décomposition

Or $AC \rightarrow B$ donc $AC \rightarrow D$ par transitivité

$$5. \quad \frac{\frac{D \rightarrow BE}{D \rightarrow B} \text{ decomp.}}{CD \rightarrow BC} \text{ aug.} \quad \frac{CD \rightarrow BC \quad BC \rightarrow A}{CD \rightarrow A} \text{ trans.}$$

2. On se limite à la première et la dernière demandées :

1. Pour $AD \rightarrow C$, les étapes successives de l'algorithme sont les suivantes :

(a) $\text{closure} = AD$

(b) $\text{closure} = ABDE$ en utilisant $D \rightarrow BE$

(c) $\text{closure} = ABCDE$ en utilisant $AE \rightarrow C$

(d) comme $C \subseteq AD^+$, on en déduit $AD \rightarrow C$ par correction de l'algorithme

2. Pour $CD \rightarrow A$, les étapes successives de l'algorithme sont les suivantes :

(a) $\text{closure} = CD$

(b) $\text{closure} = BCDE$ en utilisant $D \rightarrow BE$

(c) $\text{closure} = ABCDE$ en utilisant $BC \rightarrow A$

(d) comme $A \subseteq CD^+$, on en déduit $CD \rightarrow A$ par correction de l'algorithme

Solution de l'exercice 2

On peut expliquer que pour prouver $A \subseteq B$ on considère $x \in A$ arbitraire et on montre que $x \in B$.

1. Pour le cas de base $i = 0$, pour tout $A \in X$ on obtient une preuve de $\Sigma \vdash X \rightarrow A$ par la règle de réflexivité et on a bien $X_0 \subseteq X^*$. Pour l'induction, supposons que $X_i \subseteq X^*$, il faut montrer que $X_{i+1} \subseteq X^*$ également. Soit $W \rightarrow Z$ la dépendance utilisée pour passer de X_i à X_{i+1} . Considérons un attribut $A \in X_{i+1}$:

– soit $A \in X_i$ et $A \subseteq X^*$ par hypothèse d'induction ;

– soit $A \notin X_i$ et donc $A \in Z$. On a $W \subseteq X_i$ et $X_i \subseteq X^*$ par hypothèse d'induction. On a $W \subseteq X^*$ par transitivité et ainsi $\Sigma \vdash X \rightarrow W$ d'après le lemme. Par transitivité avec $W \rightarrow Z$, on prolonge la preuve en $\Sigma \vdash X \rightarrow Z$. Comme $A \in Z$ on a $\Sigma \vdash Z \rightarrow A$ et on peut encore prolonger par réflexivité et transitivité pour avoir $\Sigma \vdash X \rightarrow A$ et donc $A \in X^*$.

2. Par adéquation des axiomes d'Armstrong, on a $X^* \subseteq X^+ = \{A \mid \Sigma \models X \rightarrow A\}$

3. Pour le cas de base on a $X = X_0 \subseteq Y_0 = Y$. Pour l'induction considérons un attribut $A \in X_{i+1}$:

– soit $A \in X_i$ et $X_i \subseteq Y_i$ par induction. On a $A \in Y_i \subseteq Y_{i+1}$ et ainsi $X_{i+1} \subseteq Y_{i+1}$.

- soit $A \notin X_i$ et donc $A \in Z$ avec $W \rightarrow Z$ la dépendance utilisée pour passer de X_i à X_{i+1} . On a $X \subseteq X_i$ et $X_i \subseteq Y_i$ par induction. On peut donc passer de Y_i à Y_{i+1} en utilisant $W \rightarrow Z$ et ainsi $A \in Y_{i+1}$.
4. Pour le cas de base, on considère une preuve $\langle f_0 = X \rightarrow Y \rangle$ de longueur un. Ainsi,
- soit $X \rightarrow Y$ est déduit par réflexivité et $Y \subseteq X = X_0$;
 - soit $X \rightarrow Y \in \Sigma$, on a ainsi $X_1 = X_0 \cup Y$ car $X \subseteq X$ et donc $Y \subseteq X_1$
- Pour l'induction on suppose que $X^* \subseteq X_n$ pour une preuve de longueur p et on va montrer qu'il est de même pour preuve $\Sigma \vdash X \rightarrow Y$ de longueur $p + 1$. Une des trois règles d'Armstrong peut être utilisée à la dernière étape d'une preuve de longueur $p + 1$:
- pour le cas de la *réflexivité* ou le cas où $f_{p+1} \in \Sigma$: l'argument est le même que pour le cas de base (l'argument inductif est inutile);
 - pour le cas de la *transitivité* : on a deux preuves $\Sigma \vdash X \rightarrow Z$ et $\Sigma \vdash Z \rightarrow Y$ de longueurs inférieures ou égale à p . Pour la première on a $Z \subseteq X^* \subseteq X_n$ par le lemme et par induction et comme la fermeture est croissante, on obtient $Z_n \subseteq X_n$. Pour la seconde on a $Y \subseteq Z^* \subseteq Z_n$ avec le même argument (on lance l'algorithme pour calculer Z_n). On obtient ainsi $Y \subseteq X_n$.
 - pour le cas de l'*augmentation* : on a une preuve $\Sigma \vdash V \rightarrow W$ de longueur inférieure ou égale à p avec $X = ZV$ et $Y = ZW$ et il faut montrer que $ZW \subseteq (ZV)_n$. Par induction on a $W \subseteq V_n$. On a $V_n \subseteq (ZV)_n$ et $Z_n \subseteq (ZV)_n$ car la fermeture est croissante (avec $V \subseteq ZV$ et $Z \subseteq ZV$). Par transitivité de l'inclusion on a $W \subseteq (ZV)_n$. Comme $Y = Z \cup W$ et qu'on a à la fois $Z \subseteq Z_n \subseteq (ZV)_n$ et $W \subseteq (ZV)_n$ on conclut que $Y \subseteq (ZV)_n$
5. On a prouvé que $X^* \subseteq X_n$, par complétude on a $X^+ \subseteq X^*$ et ainsi $X^+ \subseteq X_n$. Comme d'autre part on a également prouvé que $X_n \subseteq X^+$ on obtient $X^* = X^+$ et l'algorithme est correct.

Solution de l'exercice 3

1. - extensive : à chaque étape X_i croît et $X_0 = X$ on a donc $X \subseteq X_n$.
 - croissante : c'est la question 3 de l'exercice précédent.
 - idempotente : intuitivement on essaie de saturer à nouveau un ensemble qui l'est déjà, plus formellement, la séquence $\langle X_0 \dots X_n \rangle$ de la première exécution de l'algorithme étant de longueur maximale, la prochaine exécution sur X^+ ne fera rien de plus.
2. Faire une approche par niveaux, calculer les fermetures de tous les singletons, puis des couples d'attributs ...

niveau 1 :

$$\begin{array}{l} \hline A^+ = A \\ B^+ = BDE \\ C^+ = CE \\ D^+ = BDE \\ E^+ = E \\ \hline \end{array}$$

niveau 2 :

$$\begin{array}{l} \hline AB^+ = R \\ AC^+ = R \\ AD^+ = R \\ AE^+ = R \\ BC^+ = R \\ BD^+ = BDE \\ BE^+ = BDE \\ CD^+ = BCDE \\ CE^+ = CE \\ \hline \end{array}$$

Se convaincre qu'il est inutile de continuer (niveau 3) car on ne pourra pas trouver de nouveaux fermés.

$$CI(\Sigma) = \{A, E, CE, BDE, BCDE, R\}$$

Eventuellement finir avec la construction de la relation d'Armstrong.