

LIF10 – FONDEMENTS DES BASES DE DONNÉES

TD5 – Relation d'Armstrong, couvertures et dépendances d'inclusion

Licence informatique – Automne 2014–2015

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

Algorithme 1: calcul d'une relation d'Armstrong

Data : R un schéma de relation, F un ensemble de DF sur R .

Result : Une relation d'Armstrong r pour F .

```
1 for  $A \in R$  do
2    $t[A] := 0$ 
3  $r := \{t\}$ 
4  $i := 1$ 
5 for  $X \in Cl(F) \setminus R$  do
6   for  $A \in R$  do
7     if  $A \in X$  then
8        $t[A] := 0$ 
9     else
10       $t[A] := i$ 
11    $r := r \cup \{t\}$ 
12    $i := i + 1$ 
13 return  $r$ 
```

Exercice 1 : relation d'Armstrong (†)

Soit un schéma de relation R et un ensemble F de DF sur ce schéma. Une *relation d'Armstrong* pour F est une relation r sur R vérifiant *exactement* F^+ . Soit le schéma $R = ABCDE$ et l'ensemble de DF $F = \{A \rightarrow BC, D \rightarrow E, C \rightarrow D\}$ pour la suite.

- (†) Calculer l'ensemble des fermés de F , défini par $Cl(F) = \{X^+ \mid X \subseteq R\}$. Pour cela, utilisez une exploration systématique des sous-ensembles de R en commençant par ceux de taille 1, puis 2... Penser à ne pas visiter les sur-ensembles des clés pour limiter le nombre de calculs.
- (†) Utiliser l'algorithme 3 pour calculer une relation d'Armstrong r .
- Supposons que l'on supprime le tuple correspondant au fermé BE de la relation r obtenue à la question précédente. Il y a-t-il des DFs nouvellement vérifiées qui ne l'étaient pas ?
- Même question que précédemment avec le fermé DE .
- Quand $F = \emptyset$, combien il y a-t-il de tuples dans la relation d'Armstrong ? Même question quand F est l'ensemble de toutes les DFs possibles sur R ?

Algorithme 2: calcul d'une couverture minimum

Data : F un ensemble de DF
Result : G une couverture minimum de F

```
1  $G := \emptyset$ 
2 for  $X \rightarrow Y \in F$  do
3    $G := G \cup \{X \rightarrow X^+\};$ 
4 for  $X \rightarrow X^+ \in G$  do
5   if  $G - \{X \rightarrow X^+\} \vdash X^+$  then
6      $G := G - \{X \rightarrow X^+\};$ 
7 return  $G;$ 
```

Algorithme 3: réduction des attributs d'un ensemble minimum de DFs

Data : Un ensemble *minimum* de DF F sur R .
Result : F avec un nombre minimal d'attributs

```
1  $Min := F$ 
   // Réduction des parties gauches
2 for  $X \rightarrow Y \in Min$  do
3    $W := X$ 
4   for  $A \in X$  do
5     if  $Min \models (W \setminus \{A\}) \rightarrow X$  then  $W := W \setminus \{A\}$ 
6    $Min := (Min \setminus \{X \rightarrow Y\}) \cup \{W \rightarrow Y\}$ 
   // Réduction des parties droites
7 for  $X \rightarrow Y \in Min$  do
8    $W := Y$ 
9   for  $A \in Y$  do
10     $G := (Min \setminus \{X \rightarrow Y\}) \cup \{X \rightarrow (W \setminus \{A\})\}$ 
11    if  $G \models X \rightarrow Y$  then  $W := W \setminus \{A\}$ 
12   $Min := (Min - \{X \rightarrow Y\}) \cup \{X \rightarrow W\}$ 
13 return  $Min$ 
```

Exercice 2 : couverture minimale (†)

- (†) Soient $F_1 = \{A \rightarrow C, AC \rightarrow D, E \rightarrow AD, E \rightarrow F\}$ et $F_2 = \{A \rightarrow CD, E \rightarrow AF\}$. Déterminer si chaque DF de F_2 peut être inférée par F_1 et réciproquement.
- En utilisant l'algorithme 2 déterminer une couverture minimale de F_1 . Comment comparer la couverture ainsi obtenue à F_2 ?
- En utilisant l'algorithme 2 déterminer si $F = \{A \rightarrow BC, D \rightarrow E, C \rightarrow D\}$ est minimal.

Exercice 3 : Couvertures non redondantes Soit l'ensemble F de DF suivant le schéma

$R = ABCDEFG :$

$D \rightarrow A$	$D \rightarrow C$	$D \rightarrow E$
$D \rightarrow F$	$CE \rightarrow G$	$AG \rightarrow F$
$ADG \rightarrow B$	$BG \rightarrow ADE$	$BF \rightarrow DG$

- Démontrer que F n'est ni optimum, ni non-redondante.
- Calculer une couverture canonique de F (couv. minimum + réduction, algorithme 3).

Exercice 4 : dépendances d'inclusion (†)

Soit $I = \{R[ABC] \subseteq S[EF], S[F] \subseteq T[J], S[FE] \subseteq T[LK]\}$ l'ensemble de dépendances d'inclusion sur le schéma de bases de données $\mathbf{D} = \{R, S, T\}$ avec $R = ABCD, S = EFGH$ et $T = IJKL$.

- (†) Prouver $I \models R[AB] \subseteq T[KL]$ à l'aide du système de Casanova donné en figure 1, en précisant σ quand la règle de permutation et projection est utilisée.

2. Enumérer les différentes DI que l'on peut produire par application de la règle de projection et permutation sur $R[ABC] \subseteq S[EFG]$. Les dénombrer dans le cas général.
3. (†) Prouver la propriété suivante d'interaction entre DFs et DIs

$$\{R[XY] \subseteq S[TU], S : T \rightarrow U\} \models R : X \rightarrow Y$$

4. Même question pour la propriété

$$\{R[XY] \subseteq S[TU], R[XZ] \subseteq S[TV], S : T \rightarrow U\} \models R[XYZ] \subseteq S[TUV]$$

$$\frac{}{R[X] \subseteq R[X]} \gamma_R \text{ (réflexivité)} \qquad \frac{R[X] \subseteq S[Y] \quad S[Y] \subseteq T[Z]}{R[X] \subseteq T[Z]} \gamma_T \text{ (transitivité)}$$

$$\frac{R[A_1 \dots A_n] \subseteq S[B_1 \dots B_n]}{R[A_{\sigma(1)} \dots A_{\sigma(k)}] \subseteq S[B_{\sigma(1)} \dots B_{\sigma(k)}]} \gamma_P \text{ (permutation \& projection)}$$

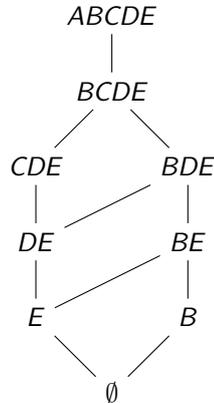
avec σ une permutation d'un sous-ensemble de $\{1 \dots n\}$

FIGURE 1 – Axiomatisation de Casanova pour les DIs

Corrections

Solution de l'exercice 1

1. On trouve les fermés suivants : $ABCDE$, $BCDE$, B , CDE , DE , E , BDE , BE . Muni de l'inclusion, on peut représenter graphiquement cet ensemble ordonné par son diagramme de Hasse :



2. On trouvera, en les considérant dans l'ordre où les fermés sont donnés :

fermé	A	B	C	D	E
$ABCDE$	0	0	0	0	0
$BCDE$	1	0	0	0	0
B	2	0	2	2	2
CDE	3	3	0	0	0
DE	4	4	4	0	0
E	5	5	5	5	0
BDE	6	0	6	0	0
BE	7	0	7	7	0

3. La relation à deux tuples composée de $\langle 7, 0, 7, 7, 0 \rangle$ associé à BE et de $\langle 0, 0, 0, 0, 0 \rangle$ associé à $ABCDE$ falsifie les DFs de la forme $BE \rightarrow X$ avec $X \in ACD$. On peut voir que parmi celles-ci c'est la DF $BE \rightarrow D$ qui n'a plus de contre exemple si on supprime $\langle 7, 0, 7, 7, 0 \rangle$. Les DFs $BE \rightarrow A$, $BE \rightarrow C$ restent quant à elles encore violées grâce à $\langle 6, 0, 6, 0, 0 \rangle$ associé à BDE .
4. Dans ce cas là, il n'y a aucun contre-exemple qui est perdu. En effet le tuple de DE permet d'invalider $DE \rightarrow A$, $DE \rightarrow B$ et $DE \rightarrow C$ mais chacune de ces DFs trouve encore un contre-exemple soit via le tuple associé à CDE soit via celui de BDE . En fait, la méthode utilisée pour générer une relation d'Armstrong produit des relations avec un nombre maximal de tuples. Pour avoir un nombre minimal il ne faut pas considérer la famille de Moore $\{ABCDE, BCDE, B, CDE, DE, E, BDE, BE\}$ mais seulement son sous-ensemble $\{ABCDE, BCDE, B, CDE, BDE, BE\}$ qui l'engendre par intersection (théorème 4.1 de *On the Structure of Armstrong Relations for Functional Dependencies*).
5. Si $F = \emptyset$ alors chaque $X \subseteq R$ est fermé et il y a ainsi $2^{|R|}$ tuples dans la relation d'Armstrong. A l'inverse, si F contient toutes les DFs possibles, alors il n'y a qu'un seul fermé $ABCDE$ et la relation obtenue ne contient qu'un seul tuple.

Solution de l'exercice 2

1. Pour la première question, on calcule $A^+ = ACD$ via F_1 et donc $F_1 \models A \rightarrow CD$. De même $E^+ = ACDEF$ et $F_1 \models E \rightarrow AF$. Dans l'autre sens c'est également le cas, et ainsi on a bien $F_1^+ = F_2^+$ et les deux ensembles sont équivalents.
2. Après la première boucle, on obtient la couverture $\{A \rightarrow ACD, AC \rightarrow ACD, E \rightarrow ACDEF\}$. Après la deuxième boucle, on supprime $AC \rightarrow ACD$ et on obtient $\{A \rightarrow ACD, E \rightarrow ACDEF\}$. On remarque que ces DFs sont minimales à gauche car composée d'un singleton mais qu'on peut les simplifier à droite pour obtenir $A \rightarrow CD$ et $E \rightarrow AF$, soit exactement F_2 .
3. On utilise l'algorithme on obtient $F' = \{A \rightarrow ABCDE; D \rightarrow DE, C \rightarrow CDE\}$ qui a le même nombre de DFs et l'ensemble est bien minimal.

Solution de l'exercice 3

1. Nous savons que $\text{Couv. Optimun} \Rightarrow \text{Couv. minimum}$ et $\text{couv. minimum} \Rightarrow \text{couv. non redondante}$. Il suffit donc d'utiliser la contraposée et de montrer que F est redondante. Pour cela, nous pouvons exhiber la DF $D \rightarrow A$ qui peut être retrouvée à l'aide des autres DFs de F .

2. Calculons d'abord la couverture minimum. Pour cela, il faut réécrire les règles sous la forme $X \rightarrow X^+$, soit l'ensemble Σ suivant :

$D \rightarrow R$
 $CE \rightarrow CEG$
 $AG \rightarrow AGF$
 $ADG \rightarrow R$
 $BG \rightarrow R$
 $BF \rightarrow R$

Notons que la DF $D \rightarrow R$ n'apparaît qu'une seule fois et pas quatre car nous adoptons une vision ensembliste (les 3 autres occurrences supprimées).

Il faut maintenant supprimer les DFs de Σ inutiles. Ici, il n'y en a qu'une seule : $ADF \rightarrow R$ ($D \rightarrow R$)

Il faut donc réduire l'ensemble suivant :

$D \rightarrow ABCDEFG$
 $CE \rightarrow CEG$
 $AG \rightarrow AGF$
 $BG \rightarrow ABCDEFG$
 $BF \rightarrow ABCDEFG$

Attention la réduction va dépendre de l'ordre dans lequel on traite les DFs. Ici, que des parties droites à réduire :

- $BF \rightarrow ABCDEFG$ simplifié en $BF \rightarrow D$ puisque $D \rightarrow R$.
- Idem pour $BG \rightarrow ABCDEFG$: $BG \rightarrow D$.
- $AG \rightarrow AGF$, il faut supprimer A et G qui apparaissent déjà en partie gauches.
- Idem pour $CE \rightarrow CEG$.
- $D \rightarrow ABCDEFG$: on peut supprimer le D (apparaît à gauche), le G (car $CE \rightarrow G$), le F ($AG \rightarrow F$) :
 $D \rightarrow ABCE$

Ce qui donne le résultat final (un parmi d'autre) :

$D \rightarrow ABCE$
 $CE \rightarrow G$
 $AG \rightarrow F$
 $BG \rightarrow ABCDEFG$
 $BF \rightarrow D$

Solution de l'exercice 4

1. Avec $\sigma_1(1) = 1, \sigma_1(2) = 2$ et $\sigma_2(1) = 2, \sigma_2(2) = 1$

$$\frac{\frac{R[ABC] \subseteq S[CFG] \quad \gamma_P(\sigma_1)}{R[AB] \subseteq S[CF]} \quad \frac{S[FE] \subseteq T[LK] \quad \gamma_P(\sigma_2)}{S[EF] \subseteq T[LK]}}{R[AB] \subseteq T[LK]}$$

2. Dans le cas général de la règle de permutation et projection, pour chaque sous-ensemble de $\{1..n\}$ de cardinalité k on peut choisir n'importe quelle permutation possible, autrement dit c'est le nombre d'arrangement de k parmi n , soit $A_n^k = n!/(n-k)!$. On peut choisir toutes les valeurs de $0 \leq k \leq n$, on a donc ainsi $\sum_{i=0}^n A_n^i$ possibilités. Dans le cas de $R[ABC] \subseteq S[CFG]$, en énumérant la partir gauche cela fait $\{\emptyset\} \cup \{A, B, C\} \cup \{AB, AC, BA, BC, CA, CB\} \cup \{ABC, ACB, BAC, BCA, CAB, CBA\}$ soit 16 possibilités. Voir <http://oeis.org/A000522>.
3. Supposons $\{r, s\}$ une base de données telle que $\{r, s\} \models \{R[XY] \subseteq S[TU], S : T \rightarrow U\}$. Il faut montrer que $r \models X \rightarrow Y$ également. Pour cela, supposons $t_0, t_1 \in r$ avec $t_0[X] = t_1[X] = \bar{x}$, $t_0[Y] = \bar{y}_0$ et $t_1[Y] = \bar{y}_1$. Comme $\{r, s\} \models R[XY] \subseteq S[TU]$, ils existent $s_0, s_1 \in s$ avec $s_0[T] = s_1[T] = \bar{x}$, $s_0[U] = \bar{y}_0$ et $s_1[U] = \bar{y}_1$. Or, comme $s \models S : T \rightarrow U$ et $s_0[T] = s_1[T]$ on a $t_0[Y] = s_0[U] = \bar{y}_0 = \bar{y}_1 = s_1[U] = t_1[Y]$ et donc $r \models X \rightarrow Y$.
4. Il faut montrer que $\forall t_0 \in r. \exists t_1 \in s. t_0[XYZ] = t_1[TUV]$. Supposons donc un tuple $t \in r$. D'une part, comme $\{r, s\} \models R[XY] \subseteq S[TU]$, on a un certain tuple $t_1 \in s$ avec $t[XY] = t_1[TU]$, et d'autre part on a un certain tuple $t_2 \in s$ avec $t[XZ] = t_2[TV]$. On illustre $\pi_{TUV}(s)$ ainsi :

	T	U	V
	\bar{x}	\bar{y}	\bar{v}
	\bar{x}	\bar{u}	\bar{z}

Or comme $t_1[T] = t_2[T] = t[X]$ et $s \models T \rightarrow U$, on a $t_1[U] = t_2[U] = t[U]$ et ainsi $t_2[TUV] = t[XYZ]$.