

2. Décomposition d'un schéma relationnel

i. Introduction

on dit qu'un schéma R est décomposé en sous schémas R1, R2, ... Rk lorsque la réunion des attributs des Ri est égal à l'ensemble des attributs de R.

$$U = X_1 \cup X_2 \dots \cup X_k$$

Exemple 1 :

ecritPar(numéro_livre, titre_livre, nb_page, auteur_nom, auteur_adresse, éditeur, éditeur_adresse)
peut être décomposée en :

R1(numéro_livre, titre_livre, nb_page, auteur_nom)

R2(auteur_nom, auteur_adresse)

R3(éditeur, éditeur_adresse)

Car la réunion de tous les attributs des Ri redonne bien les attributs de écritPar.

ii. Décomposition sans perte d'information

On dit que la décomposition est sans perte d'information, notée SPI, si et seulement si pour toute instance r de R :

$$\text{Si } r_i = \text{proj}(r) / X_i \text{ alors } r = r_1 \bowtie r_2 \bowtie \dots \bowtie r_k$$

C'est-à-dire que la jointure de l'ensemble des sous schémas redonne exactement le schéma initial ou encore que les tables des projections suffisent à reconstituer la table de départ.

Dans l'exemple écritPar cité plus haut, la décomposition est avec pertes. Car on ne connaît plus l'éditeur du livre.

Par contre la décomposition suivante :

R4(numéro_livre, auteur_nom, éditeur_nom)

R5(numéro_livre, titre_livre, nb_page)

R6(auteur_nom, auteur_adresse)

R7(éditeur_nom, éditeur_adresse)

est une décomposition sans perte de écritPar(numéro_livre, titre_livre, nb_page, auteur_nom, auteur_adresse, éditeur_nom, éditeur_adresse)

Ceci provient du fait que le numéro du livre détermine son titre et son nombre de pages, le nom de l'auteur détermine son adresse ainsi que le nom de l'éditeur qui détermine son adresse également.

Lemme 1 :

Soit $U = X \cup Y \cup Z$ réunion d'ensembles disjoints d'attributs.

Soit R un schéma relationnel défini sur U, sur lequel existe la dépendance fonctionnelle $X \rightarrow Y$ alors la décomposition $R_1(X, Y) R_2(Y, Z)$ est sans perte pour R.

iii. Test de décomposition sans perte d'information

Soit R un schéma relationnel, F un ensemble de dépendances fonctionnelles, $R_1, R_2 \dots R_k$ une décomposition.

Construire un tableau T ayant k lignes et n colonnes : La colonne j correspond à l'attribut A_j , la ligne i correspond au sous schéma R_i

Algorithme de poursuite:

Première phase :

Dans chaque case $T[i,j]$ du tableau, on mettra a_i si l'attribut A_i appartient à R_i et b_{ij} sinon.

Deuxième phase :

Pour chaque dépendance $X \rightarrow Y$ de F, chaque fois que l'on trouve deux lignes ayant les mêmes valeurs (a ou b) pour les attributs de X on égalise les cases correspondant aux attributs de Y, en mettant prioritairement des a_i .

Important : chaque fois que deux symboles sont égalisés il faut veiller à remplacer toutes les occurrences du symbole modifié.

Il faut répéter ces opérations jusqu'à ce que le tableau ne varie plus ou bien jusqu'à ce qu'apparaisse une ligne ne contenant que des a_i : dans ce dernier cas seulement, la décomposition est sans perte.

Exemple 1

$R(A,B,C,D)$

$F \{AB \rightarrow C, A \rightarrow D\}$

$R_1(A,B,C)$

$R_2(A,D)$

Au départ

R	A	B	C	D
R1	a_1	a_2	a_3	b_{14}
R2	a_1	b_{22}	b_{23}	a_4

$AB \rightarrow C$ n'apporte aucune modification (il faudrait pour cela que $b_{22} = a_2$) auquel cas on changerait b_{23} en a_3

Par contre du fait de $A \rightarrow D$

R	A	B	C	D
R1	a_1	a_2	a_3	a_4
R2	a_1	b_{22}	b_{23}	a_4

On a donc une ligne ne contenant que des a_i et donc la décomposition est Sans Perte d'Information.

Remarque (dans cet exemple on pouvait appliquer le lemme vu plus haut puisque A est une clef de R2

exemple 2 :

$R(A,B,C,D,E)$

$F \{A \rightarrow C, B \rightarrow C, C \rightarrow D, DE \rightarrow C, CE \rightarrow A\}$

$R_1(A,D)$

$R_2(A,B)$

$R_3(B,E)$

$R_4(C,D,E)$

$R_5(A,E)$

Au départ on a donc

R	A	B	C	D	E
R_1	a_1	b_{12}	b_{13}	a_4	b_{15}
R_2	a_1	a_2	b_{23}	b_{24}	b_{25}
R_3	b_{31}	a_2	b_{33}	b_{34}	a_5
R_4	b_{41}	b_{42}	a_3	a_4	a_5
R_5	a_1	b_{52}	b_{53}	b_{54}	a_5

En appliquant $A \rightarrow C$

R	A	B	C	D	E
R_1	a_1	b_{12}	b_{13}	a_4	b_{15}
R_2	a_1	a_2	b_{13}	b_{24}	b_{25}
R_3	b_{31}	a_2	b_{33}	b_{34}	a_5
R_4	b_{41}	b_{42}	a_3	a_4	a_5
R_5	a_1	b_{52}	b_{13}	b_{54}	a_5

En appliquant $B \rightarrow C$

R	A	B	C	D	E
R_1	a_1	b_{12}	b_{13}	a_4	b_{15}
R_2	a_1	a_2	b_{13}	b_{24}	b_{25}
R_3	b_{31}	a_2	b_{13}	b_{34}	a_5
R_4	b_{41}	b_{42}	a_3	a_4	a_5
R_5	a_1	b_{52}	b_{13}	b_{54}	a_5

En appliquant $C \rightarrow D$

R	A	B	C	D	E
R ₁	a ₁	b ₁₂	b ₁₃	a ₄	b ₁₅
R ₂	a ₁	a ₂	b ₁₃	a ₄	b ₂₅
R ₃	b ₃₁	a ₂	b ₁₃	a ₄	a ₅
R ₄	b ₄₁	b ₄₂	a ₃	a ₄	a ₅
R ₅	a ₁	b ₅₂	b ₁₃	a ₄	a ₅

En appliquant DE → C

R	A	B	C	D	E
R ₁	a ₁	b ₁₂	a ₃	a ₄	b ₁₅
R ₂	a ₁	a ₂	a ₃	a ₄	b ₂₅
R ₃	b ₃₁	a ₂	a ₃	a ₄	a ₅
R ₄	b ₄₁	b ₄₂	a ₃	a ₄	a ₅
R ₅	a ₁	b ₅₂	a ₃	a ₄	a ₅

– car tous les b₁₃ se changent en a₃
En appliquant CE → A

R	A	B	C	D	E
R ₁	a ₁	b ₁₂	a ₃	a ₄	b ₁₅
R ₂	a ₁	a ₂	a ₃	a ₄	b ₂₅
R ₃	a ₁	a ₂	a ₃	a ₄	a ₅
R ₄	a ₁	b ₄₂	a ₃	a ₄	a ₅
R ₅	a ₁	b ₅₂	a ₃	a ₄	a ₅

Comme la ligne R₃ ne contient que des a_i la décomposition est SPI.

Exemple 3 :

On reprend l'exemple 2

En prenant

R(A,B,C,D,E)

F {A → C, B → C, C → D, DE → C, CE → A}

R₁(A,D)

R₂(A,B)

R₃(B,E)

R₄(C,D)

R₅(A,E)

Au départ on a donc

R	A	B	C	D	E
R ₁	a ₁	b ₁₂	b ₁₃	a ₄	b ₁₅
R ₂	a ₁	a ₂	b ₂₃	b ₂₄	b ₂₅
R ₃	b ₃₁	a ₂	b ₃₃	b ₃₄	a ₅
R ₄	b ₄₁	b ₄₂	a ₃	a ₄	b ₄₅
R ₅	a ₁	b ₅₂	b ₅₃	b ₅₄	a ₅

Comme précédemment on obtient le tableau

R	A	B	C	D	E
R ₁	a ₁	b ₁₂	b ₁₃	a ₄	b ₁₅
R ₂	a ₁	a ₂	b ₁₃	a ₄	b ₂₅
R ₃	b ₃₁	a ₂	b ₁₃	a ₄	a ₅
R ₄	b ₄₁	b ₄₂	a ₃	a ₄	b ₄₅
R ₅	a ₁	b ₅₂	b ₁₃	a ₄	a ₅

Mais plus aucune DF n'apporte de modifications ! La décomposition n'est pas SPI !

Dans le cas d'un schéma R(X, Y, Z) décomposé en deux sous schémas R₁(X, Y), R₂(Y, Z) (on suppose X, Y et Z des ensembles d'attributs disjoints) la décomposition est sans perte si et seulement si Y → X ou bien Y → Z

3. Décompositions sans perte de dépendances

On choisit de stocker les données suivant une décomposition S du schéma

→ il faut vérifier que la base reste cohérente, i.e. qu'elle satisfait les df

→ à chaque m.a.j., il faut reconstruire la relation sur le schéma de départ U, sur lequel sont énoncées les df.

Problème : les jointures sont coûteuses

→ est-il possible de vérifier la cohérence de la base sans reconstruire la relation sur U, i.e. en se servant uniquement des relations stockées ?

→ oui si S « incorpore » un ensemble de df G équivalent à F

Exemple : Soit la relation **Examen(module, date, étudiant)** avec l'ensemble de dépendances F (module → date, étudiant → date → module) signifiant qu'un module est associée à une date unique (examen par exemple) et qu'à une date donnée un étudiant ne peut passer qu'un seul module.

La décomposition en $R_1(\text{module, date})$ et $R_2(\text{module, étudiant})$ est sans perte d'information mais on ne peut vérifier que la dépendance $\text{étudiant,date} \rightarrow \text{module}$ est bien respectée sauf à reconstituer la table initiale (ce que l'on souhaite éviter, en général)

On dit que cette dépendance a été perdue dans la décomposition. L'idée va donc consister à prendre des décompositions de sorte que l'on puisse vérifier un ensemble de dépendances (dans chaque sous schéma) suffisant pour être certain que toutes les dépendances de F sont bien vérifiées.

Soit une relation R et une décomposition $R_1, R_2 \dots R_n$

Soit G_i la projection de F^+ sur R_i

Remarque : $G_i = G_i^+ \text{ et } G$, union des G_i est dans F^+ .

La décomposition sera sans perte de dépendance si $G^+ = F^+$

Remarque : si l'on note F_i la projection de F (et non de F^+) sur R_i , F_i est inclus dans G_i mais ce n'est pas nécessairement réciproque.

Exemple

Soit $R(A,B,C)$, $F=\{A \rightarrow B, B \rightarrow C\}$ et $R_1(B,C)$ $R_2(A,C)$ (on remarquera, que la décomposition est bien SPI)
 $F_1 = \{B \rightarrow C\}$ et $F_2 = \{A \rightarrow C\}$ mais $F^+ = \{A \rightarrow B, B \rightarrow C, A \rightarrow C\}$ + les DF triviales donc $G_1 = \{B \rightarrow C\}$ + les DF triviales et $G_2 = \{A \rightarrow C\}$ + les DF triviales. Il est clair que $G = (G_1 \cup G_2)$ ne contient pas F^+ car il manque $A \rightarrow B$ donc la décomposition n'est pas Sans Perte de Dépendance mais on voit bien que G_2 contient strictement F_2 .

Remarque : une décomposition peut être SPD sans être SPI.

Exemple :

$R(A,B,C,D)$
 $F=\{A \rightarrow B, C \rightarrow D\}$
 $R_1(AB), R_2(CD)$

Il est clair que $F = F_1 \cup F_2$. Comme G_i contient F_i , G contient F donc F^+ . La décomposition est Sans Perte de Dépendance, pourtant elle n'est pas SPI car $R_1 \text{ inter } R_2$ est vide et contredirait le lemme concernant la décomposition de 2 relations.