

5.5 Décompositions d'un schéma : propriétés SPI et SPD

A nouveau l'exemple de mauvais schéma, donnant lieu à des redondances et des anomalies, déjà considéré :

Relation FOURNISSEUR

<i>Nom</i>	<i>Adr</i>	<i>Produit</i>	<i>Prix</i>
n1	a1	i1	p1
n1	a1	i2	p2
n2	a2	i2	p3
n2	a2	i3	p4

$$F = \text{Nom} \rightarrow \text{Adr}, \text{Nom Produit} \rightarrow \text{Prix}$$

Il faudrait le remplacer par un autre schéma. Comment ?

Une solution possible : **décomposer** le schéma de relation en 2 ou plusieurs sous-schémas. Par ex. décomposer :

FOURNISSEUR(*Nom, Adr, Produit, Prix*)

en :

NA(*Nom, Adr*) et NIP(*Nom, Produit, Prix*)

Contenu de la table NA : $\pi_{Nom,Adr}(\text{FOURNISSEUR})$.

Contenu de la table NIP : $\pi_{Nom,Produit,Prix}(\text{FOURNISSEUR})$.

Ceci est un exemple de la **façon générale de décomposer une table de schéma S** en n tables de schémas S_1, \dots, S_n où $(S_1 \cup \dots \cup S_n) = S$:
on projette le contenu de la table décomposée sur les sous-schémas.

- **Toute décomposition possible est OK ?**
- Un des critères qu'une bonne décomposition doit respecter : **il faut pouvoir reconstruire, par jointure, la relation de départ.**

- Dans notre exemple :

$\pi_{Nom,Adr}(FOURNISSEUR) \bowtie \pi_{Nom,Produit,Prix}(FOURNISSEUR) =$
 $FOURNISSEUR ?$ OUI.

- **Toujours vrai, peu importe la décomposition ? NON.** Contre-ex : Table R :

A	B	C
a1	b1	c1
a2	b1	c2

Décomposition en $R_1(A,B)$ et $R_2(B,C)$ (contenus=projections de R).

$\langle a1, b1, c2 \rangle \in (\pi_{A,B}(R) \bowtie \pi_{B,C}(R))$ mais $\langle a1, b1, c2 \rangle \notin R !$

Cette décomposition **fait perdre l'information NEGATIVE** :

“ $\langle a1, b1, c2 \rangle$ n'est pas une ligne de R”.

- Soit F un ensemble de DF. Une décomposition d'un schéma S d'une table R en S_1, \dots, S_n (où $(S_1 \cup \dots \cup S_n) = S$) est dite **sans perte d'information (SPI) par rapport à F** ssi, qqe soit le contenu de la table de nom R :

$$(\pi_{S_1}(R) \bowtie \dots \bowtie \pi_{S_n}(R)) = R$$

- *N.B.* :

$$R \subseteq (\pi_{S_1}(R) \bowtie \dots \bowtie \pi_{S_n}(R))$$

est toujours vrai, la \subseteq réciproque non (contre-exemple précédant).

Rôle de F ??



Pour le schéma de table de l'exemple précédant, on n'aurait pas pu avoir perte d'information négative si $B \rightarrow C$ ou $B \rightarrow A$:

on obtient $\langle a1, b1, c2 \rangle \in (\pi_{A,B}(R) \bowtie \pi_{B,C}(R))$ mais $\langle a1, b1, c2 \rangle \notin R$ car R ne satisfait pas $B \rightarrow C$ et ne satisfait pas $B \rightarrow A$

Soit $S = \{A, B, C\}$ un schéma de table et soit F un ensemble de DF sur S .
Si F implique $B \rightarrow C$ ou $B \rightarrow A$, alors la déc. de S en $\{A, B\}$ et $\{B, C\}$ est forcément SPI par rapport à F .

Remarque :

$$B \rightarrow A = (\{A, B\} \cap \{B, C\} \rightarrow (\{A, B\} \setminus \{B, C\}))$$

$$B \rightarrow C = (\{A, B\} \cap \{B, C\} \rightarrow (\{B, C\} \setminus \{A, B\}))$$

Théorème : Une déc. de S en red 2 sous-schémas S_1 et S_2 est SPI par rapport à un ensemble de dépendances fonctionnelles F ssi F implique

$$(S_1 \cap S_2) \rightarrow (S_1 \setminus S_2)$$

ou

$$(S_1 \cap S_2) \rightarrow (S_2 \setminus S_1)$$

NB : ce théorème donne un algo pour **tester** si une décomposition en 2 est SPI par rapport à F .

Et si on veut décomposer en n tables où $n > 2$? Algo qui **teste** si une déc. est SPI : **chase**. **A voir en TD**.

Critère 1 qu'une décomposition doit respecter : être **SPI** par rapport aux DF.

- SPI : seul critère à souhaiter pour une déc. d ?
- **Exemple.** V : ville, R : rue, C : Code Postal. Schéma : INFOS(R,C,V).
 $F = \{VR \rightarrow C, C \rightarrow V\}$.
 Déc. d en INFO1(RC) et INFO2(CV) :

	INFOS	
R	C	V
r1	c1	v1
r1	c2	v2
r3	c3	v3

INFO1	
R	C
r1	c1
r1	c2
r3	c3

INFO2	
C	V
c1	v1
c2	v2
c3	v1

d est SPI car F implique $((RC) \cap (CV)) \rightarrow (CV \setminus RC)$.

Mais que dévient $VR \rightarrow C$? Pas applicable.

Insertion de $\langle r1, c3 \rangle$ dans INFO1 : OK par rapport aux dép de INFO1, mais :
 $\langle r1, c3, v1 \rangle$ et $\langle r1, c1, v1 \rangle \in \text{INFO1} \bowtie \text{INFO2}$. **Violation de $VR \rightarrow C$!**

La décomposition l'exemple précédent ne fait pas perdre d'information mais elle **fait perdre des dépendances fonctionnelles**.

Pour savoir si une insertion préserve la contrainte $VR \rightarrow C$ il faudrait réfaire la jointure $INFO1 \bowtie INFO2$!

On aimerait travailler sans besoin de faire des \bowtie chaque fois qu'on insère.

Formalisons : \Rightarrow

Déf. La *fermeture* d'un ensemble de DF F , noté F^+ , est l'ensemble de *toutes* les dép. impliquées par F .

Déf. La *projection* d'un ensemble de dép. F sur un ensemble d'attributs X est l'ensemble d'éléments de F^+ (pas seulement de F !) comportant seulement des attributs de X . Notation : F_X .

Déf. Une décomposition d de S en $S_1 \cdots S_n$ est **sans perte de dépendances (SPD) par rapport à un ensemble de dép. F** ssi

$$(F_{S_1} \cup \cdots \cup F_{S_n})^+ = F^+$$

NB : \subseteq est banal. C'est l'inclusion réciproque qui compte.

(Le pb. crucial est : risque-t-on de perdre des dépendances impliquées par F , en projetant sur les sous-schémas ?)

Exemple de calcul de F_{S_i} . Soit $S = \{A, B, C\}$, $S_1 = \{A, C\}$

$$F = \{A \rightarrow B, B \rightarrow A, B \rightarrow C, C \rightarrow B\}.$$

$$F^+ = \{A \rightarrow A, A \rightarrow B, A \rightarrow C, \\ B \rightarrow A, B \rightarrow B, B \rightarrow C, \\ C \rightarrow A, C \rightarrow B, C \rightarrow C, \dots\}$$

F_{S_1} contient $A \rightarrow C$ et $C \rightarrow A$ (même si $C \rightarrow A \notin F$!) et toutes les dépendances impliquées par ces deux là.

Attention : Oublier que $A \rightarrow C$ et $C \rightarrow A$ sont dans F_{S_1} est un exemple typique d'erreur !

Exemple de déc. Soit $S = \{A, B, C\}$, $S_1 = \{A, B\}$, $S_2 = \{B, C\}$,
 $F = \{A \rightarrow B, B \rightarrow C, C \rightarrow A\}$. Soit d une décomposition de S en S_1 et S_2 .

SPD ? Clair que l'on retrouve $A \rightarrow B$ et $B \rightarrow C$. Mais $C \rightarrow A$??

$$B \rightarrow A \in F_{S_1}$$

$$C \rightarrow B \in F_{S_2}$$

$$\{C \rightarrow B, B \rightarrow A\} \subset (F_{S_1} \cup F_{S_2})$$

$$C \rightarrow A \in (F_{S_1} \cup F_{S_2})^+$$

$$\text{Donc } F \subseteq (F_{S_1} \cup F_{S_2})^+.$$

$$\text{Donc } F^+ \subseteq (F_{S_1} \cup F_{S_2})^+.$$

OUI, SPD !

- Critère 2 qu'une décomposition doit respecter : être SPD par rapport aux dépendances fonctionnelles.
- Une déc. d peut être SPI sans être SPD : ex. vu.
- Une déc. d peut être SPD sans être SPI. Etudier la déc. de :

A	B	C	D
a	b	c1	d1
a1	b1	c	d

$$F = \{A \rightarrow B, C \rightarrow D\}$$

en AB et CD.

- **Question.** Existe-t-il un algo qui engendre une décomposition qui est forcément SPI et SPD par rapport aux DF ? **OUI.**

Préliminaires à la déf. de l'algo qui engendre une décomposition SPI et SPD par rapport à un ensemble de dépendances fonctionnelles F

Soit $X \rightarrow Y$ une dép. fonct. et soit F un ensemble de dép. fonct..

DEFINITIONS

- $X \rightarrow Y$ est **réduite à droite** si Y est un singleton.
- $X \rightarrow Y$ est **réduite à gauche** (par rapport à F) s'il n'existe pas de X' strictement inclus dans X t.q. F implique $X' \rightarrow Y$.
- F est **redondant** s'il existe une dép. fonct. $Z \rightarrow W \in F$ t.q. $F \setminus \{Z \rightarrow W\}$ implique $Z \rightarrow W$.
- F est **réduit** si
 1. F n'est pas redondant
 2. $\forall f \in F, f$ est réduite à gauche **et** à droite.

Exemple.

Soit $F =$

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

1. Les dép. de F sont réduites à droite, mais ne sont pas réduites à gauche. On a : $AB \rightarrow C \in F$, mais F implique $B \rightarrow C$.
(Calculer $\{B\}_F^+$!) L'ensemble $\{F\}$ est strictement inclus dans $\{A, B\}$.
2. F est redondant, car $F \setminus \{AB \rightarrow C\}$ implique $AB \rightarrow C$.
(Calculer $\{AB\}_{F \setminus \{AB \rightarrow C\}}^+$!)

- **Définition**

Soit F un ensemble de dép. fonct. Une **couverture** de F est un ensemble G de dép. fonct. tq. F est **équivalent à G** (c.à.d. : $F^+ = G^+$). Une **couverture minimale** de F est un ensemble G de dép. fonct. tq. G est réduit et F est équivalent à G .

- **Exemple très simple**

$$F = \{A \rightarrow BC, AC \rightarrow D, A \rightarrow D\}$$

F n'est pas réduit : $A \rightarrow BC$ n'est pas réduite à droite, $AC \rightarrow D$ n'est pas réduite à gauche, et F est redondant, car $F \setminus \{A \rightarrow D\}$ implique $A \rightarrow D$.

Soit :

$$G = \{A \rightarrow B, A \rightarrow C, A \rightarrow D\}$$

G est une couverture minimale de F (développement au tableau).

- Calcul **mécanique** d'une couverture minimale pour un ensemble de dép. fonct. quelconque ?

Algorithme de Calcul d'une Couverture Minimale

Entrée : Un ensemble F de dép. fonct.

Sortie : Une couverture minimale G de F

1. *Initialisation* : $G := F$;

2. **Faire**, dans l'ordre :

(a) Remplacer toute $X \rightarrow A_1, \dots, A_n$ de F tq $n > 1$ par les dép.

$X \rightarrow A_1, \dots, X \rightarrow A_n$.

$G :=$ l'ensemble de dép. ainsi obtenu;

(b) Remplacer toute $X \rightarrow Y \in G$ par $X' \rightarrow Y$ où X' est un sous-ensemble minimal de X tq G implique $X' \rightarrow Y$.

$G :=$ l'ensemble de dép. ainsi obtenu;

(c) Tant que il existe $X \rightarrow A \in G$ tq $G \setminus \{X \rightarrow A\}$ implique $X \rightarrow A$,

faire $G := G \setminus \{X \rightarrow A\}$;

3. **Retourner** G

Dans l'algorithme de calcul de la couverture minimale de F :

- Dans l'étape 2b, comment trouver un sous-ensemble minimal X' de X tq G implique $X' \rightarrow Y$?
On peut calculer E^+_G pour tout sous-ensemble strict E de X , en partant des sous-ensembles les + petits.
- Dans l'étape 2c, comment tester s'il existe $X \rightarrow A \in G$ tq $G \setminus \{X \rightarrow A\}$ implique $X \rightarrow A$?
On peut calculer $X^+_{G \setminus \{X \rightarrow A\}}$ pour toute $X \rightarrow A \in G$.

Attention ! Il faut faire les étapes 2a et 2b **avant** l'étape 2c !!

Exemple

On fait tourner l'algo de calcul d'une couverture minimale sur :

$$F_1 = \{ABCD \rightarrow E, E \rightarrow D, A \rightarrow B, AC \rightarrow D\}$$

Mauvaise façon de faire

1. On fait l'étape 2c tout de suite : rien est redondant !
2. Etape 2a : rien à faire.
3. Etape 2b : on remplace $ABCD \rightarrow E$ par $AC \rightarrow E$.

Fini ! On a obtenu $F_2 = \{AC \rightarrow E, E \rightarrow D, A \rightarrow B, AC \rightarrow D\}$ qui est équivalent à F_1 , mais qui contient la dépendance redondante $AC \rightarrow D$! Une couverture minimale aurait été

$$F_3 = \{AC \rightarrow E, E \rightarrow D, A \rightarrow B, \}$$

On fait à nouveau tourner l'algorithme de calcul d'une couverture minimale sur :
 $F_1 = \{ABCD \rightarrow E, E \rightarrow D, A \rightarrow B, AC \rightarrow D\}$, mais avec le bon ordre des étapes.

1. On fait l'étape 2a : rien à faire
2. Etape 2a : on obtient $F'_1 = \{AC \rightarrow E, E \rightarrow D, A \rightarrow B, AC \rightarrow D\}$
3. Etape 2c : on élimine $AC \rightarrow D$.
4. Fini, avec le bon ensemble F_3 comme résultat !

On est prêts à donner l'algo pour le calcul d'une déc. qui soit SPI et SPD \rightsquigarrow
page suivante.

Algorithme qui génère une dec. SPI et SPD

Entrée : Un schéma de relation S , un ensemble F de dép. fonct. sur S .

Sortie : Une décomposition d de S qui est SPI et SPD par rapport à F .

1. Choisir un ensemble de DF $F' = \{X_1 \rightarrow A_1, \dots, X_n \rightarrow A_n\}$ tq F' est une couverture minimale de F ;
2. Pour chaque $f_i = X \rightarrow A_j \in F'$, créer un schéma $S_i = XA_j$ et poser $d =$ l'ensemble de ces S_i .
3. Si aucune des clés de S (calculées grâce à F') n'est contenue dans un élément de d , modifier d en y ajoutant une clé Y comme élément.
4. S'il existe 2 éléments S_i et S_j de d tels que $S_i \subset S_j$ supprimer S_i , afin d'obtenir la valeur courante de d .
5. Si on a des éléments de d de la forme XA_1, \dots, XA_k obtenus car $X \rightarrow A_1, \dots, X \rightarrow A_k$ sont des éléments de F' , les remplacer par l'unique (sous)schéma $XA_1 \dots A_k$ afin d'obtenir la valeur finale de d .

N.B Si plusieurs choix de couvertures minimales et de clés, possibilité de plusieurs décompositions.

Exemple d'application.

Soit $S = ABCDE$. Soit

$$F_1 = \{ABCD \rightarrow E, E \rightarrow D, A \rightarrow B, AC \rightarrow D\}$$

Application de l'algo de décomposition SPI et SPD : au tableau.