

Bases de Données : Forme normale de Boyce-Codd (BCNF)

Stéphane Devismes
Université Grenoble Alpes
26 août 2020

Plan

- 1 Définition et propriétés
- 2 Normalisation BCNF : algorithme récursif
- 3 Normalisation BCNF : algorithme de synthèse

Rappel (1/2)

Pour tout ensemble d'attributs A de R on a

$A^+ = S$, où S est l'ensemble de tous les attributs de la relation R

si et seulement si

A contient une clé, autrement dit A est superclé

Rappel (2/2)

Pour tout ensemble d'attributs A de R on a

$A^+ = A$

si et seulement si

les seuls attributs déterminés par A sont ceux qui font partie de A .

Définition

Une relation R est en **forme normale de Boyce-Codd** (BCNF) si pour tout ensemble d'attributs A de R on a

$A^+ = A$ ou $A^+ = S$, où S est l'ensemble de tous les attributs de la relation R .

Cela signifie que **s'il y a une dépendance $A \rightarrow b$ avec $b \notin A$, alors A est une superclé**.

Propriété

Une relation R est en **BCNF** si et seulement si pour tous ensembles d'attributs A et B de R , on a

$$A \rightarrow B$$

si et seulement si :

- ou bien $B \subseteq A$ (dépendance **triviale**),
- ou bien A contient une clé (*i.e.*, A est une **superclé**) de R .

Preuve de la propriété

Soit R une **relation BCNF**. Soient A et B deux ensembles d'attributs de R .

Supposons $A \rightarrow B$. D'après la définition, on a $A^+ = A$ ou $A^+ = S$.

Si $A^+ = A$, alors on a nécessairement $B \subseteq A$ (d'après l'algorithme de clôture).

Si $A^+ = S$, alors, par définition, A est une superclé de R , donc A **contient une clé de R** .

Supposons $B \subseteq A$ ou A **contient une clé de R** .

Dans le premier cas, on a $A \rightarrow B$ **par réflexivité**.

Dans le second cas, on a $A^+ = S$ et donc $A \rightarrow S$. Or **par réflexivité**,

$S \rightarrow B$ et, **par transitivité**, $A \rightarrow B$.

Preuve de la propriété (suite)

Soit R une relation telle que pour tous ensembles d'attributs A et B de R , on a

$$A \rightarrow B$$

si et seulement si :

- ou bien $B \subseteq A$ (dépendance **triviale**),
- ou bien A contient une clé (*i.e.*, A est une **superclé**) de R .

Soit C un ensemble d'attributs.

Si $C^+ \neq C$ alors, d'après l'algorithme de clôture, il existe une dépendance fonctionnelle $A \rightarrow B$ telle que $A \subseteq C$ et $B \not\subseteq A$.

Donc A **contient une clé**, c'est-à-dire, $A^+ = S$.

De $A \subseteq C$ et $A^+ = S$, on a $C^+ = S$ (la clôture préserve les inclusions)

Ainsi, $C^+ = C$ ou $C^+ = S$: **R est BCNF**.

Exemple

Soit $R(a, b)$ avec la base de dépendances fonctionnelles $a \rightarrow b$,
 $b \rightarrow a$.

Alors R a deux clés (a et b).

Soit $R(a, b, c)$ avec la base de dépendances fonctionnelles $a \rightarrow b$,
 $b \rightarrow c$.

Décomposition en BCNF

Une décomposition $R = R[S_1] * \dots * R[S_n]$ est en **forme normale de Boyce-Codd** (BCNF) si chaque $R[S_i]$ est en BCNF.

Propriété

Si une relation R est en BCNF alors dès qu'on connaît les clés de R , on peut en déduire toutes ses dépendances.

En effet, étant donné un ensemble d'attributs A de R :

- soit A contient une clé et alors $A^+ = S$, où S est l'ensemble de tous les attributs de la relation R .
- soit A ne contient pas de clé et alors $A^+ = A$.

Algorithme récursif de normalisation BCNF

Entrée. Une relation R , l'ensemble S des attributs de R et une base \mathcal{D} de dépendances fonctionnelles singletons pour R .

Sortie. $Res = \{S_1, \dots, S_n\}$ où les S_i fournissent une décomposition de R en BCNF qui évite les redondances (mais ne préserve pas toujours les dépendances).

-T- Pour chaque dépendance fonctionnelle $A \rightarrow b$ de \mathcal{D} par ordre croissant de cardinal de partie gauche

Si A vérifie $A^+ \subsetneq S$ alors passer à (B).

-RET0 - Si le test précédent est toujours faux, alors

R est en BCNF, poser $Res = \{S\}$ et retourner Res .

-B- Soit A avec $A^+ \subsetneq S$.

Poser $S_1 = A^+$ et $S_2 = A \cup (S - A^+)$.

Poser $R_1 = R[S_1]$ et $\mathcal{D}_1 =$ le sous-ensemble de \mathcal{D}

formé des dépendances fonctionnelles dont tous les attributs sont dans S_1 .

Appel récursif avec R_1, S_1 et \mathcal{D}_1 . Soit Res_1 le résultat.

Poser $R_2 = R[S_2]$ et $\mathcal{D}_2 =$ le sous-ensemble de \mathcal{D}

formé des dépendances fonctionnelles dont tous les attributs sont dans S_2 .

Appel récursif avec R_2, S_2 et \mathcal{D}_2 . Soit Res_2 le résultat.

-RET- Poser $Res = Res_1 \cup Res_2$ et retourner Res .

Exemples (1/4)

Soit $R(I, o, s, b)$ avec la base $\{I \rightarrow o, I \rightarrow s, s \rightarrow b\}$.

$I^+ = losb = S$, mais $s^+ = sb \subsetneq S$, donc :

On pose $A = s$, $S_1 = A^+ = sb$ et $S_2 = AU(S - A^+) = los$.

- 1 Appel récursif sur $R_1 = R[sb]$ avec $\{s \rightarrow b\}$: $s^+ = sb$, donc R_1 est BCNF de clé s , stop.
- 2 Appel récursif sur $R_2 = R[los]$ avec $\{I \rightarrow o, I \rightarrow s\}$: $I^+ = os$, donc R_2 est BCNF de clé I , stop.

Donc $R_1 * R_2$, où $\{s \rightarrow b\}$ est la base de $R_1 = R[sb]$ et $\{I \rightarrow o, I \rightarrow s\}$ est la base de $R_2 = R[los]$, est **une décomposition BCNF** sans perte de dépendances fonctionnelles.

Exemples (3/4)

Soit $R(I, o, s, b)$ avec la base $\{I \rightarrow o, I \rightarrow s, s \rightarrow b, o \rightarrow b\}$.

$o^+ = ob \subsetneq S$, donc :

On pose $A = o$, $S_1 = A^+ = ob$ et $S_2 = AU(S - A^+) = los$.

- 1 Appel récursif sur $R_1 = R[ob]$ avec $\{o \rightarrow b\}$: $o^+ = ob$, donc R_1 est BCNF de clé o , stop.
- 2 Appel récursif sur $R_2 = R[los]$ avec $\{I \rightarrow o, I \rightarrow s\}$: $I^+ = los$, donc R_2 est BCNF de clé I , stop.

Donc $R_1 * R_2$, où $\{o \rightarrow b\}$ est la base de $R_1 = R[ob]$ et $\{I \rightarrow o, I \rightarrow s\}$ est la base de $R_2 = R[los]$, est **une décomposition BCNF**, mais elle ne préserve pas les dépendances : on a « perdu » $s \rightarrow b$.

Exemples (2/4)

Soit $R(I, o, s, b)$ avec la base $\{I \rightarrow o, I \rightarrow s, s \rightarrow b, o \rightarrow b\}$.

$s^+ = sb \subsetneq S$, donc :

On pose $A = s$, $S_1 = A^+ = sb$ et $S_2 = AU(S - A^+) = los$.

- 1 Appel récursif sur $R_1 = R[sb]$ avec $\{s \rightarrow b\}$: $s^+ = sb$, donc R_1 est BCNF de clé s , stop.
- 2 Appel récursif sur $R_2 = R[los]$ avec $\{I \rightarrow o, I \rightarrow s\}$: $I^+ = los$, donc R_2 est BCNF de clé I , stop.

Donc $R_1 * R_2$, où $\{s \rightarrow b\}$ est la base de $R_1 = R[sb]$ et $\{I \rightarrow o, I \rightarrow s\}$ est la base de $R_2 = R[los]$, est **une décomposition BCNF**, mais elle ne préserve pas les dépendances : on a « perdu » $o \rightarrow b$.

Exemples (4/4)

Soit $R(p, m, e)$ avec la base $\{p \rightarrow m, me \rightarrow p\}$.

$p^+ = pm \subsetneq S$, donc :

On pose $A = p$, $S_1 = A^+ = pm$ et $S_2 = AU(S - A^+) = pe$.

- 1 Appel récursif sur $R_1 = R[pm]$ avec $\{p \rightarrow m\}$: $p^+ = pm$, donc R_1 est BCNF de clé p , stop.
- 2 Appel récursif sur $R_2 = R[pe]$ avec \emptyset : R_2 est BCNF de clé pe , stop.

Donc $R_1 * R_2$, où $\{p \rightarrow m\}$ est la base de $R_1 = R[pm]$ et la base de $R_2 = R[pe]$ est vide, est **une décomposition BCNF**, mais elle ne préserve pas les dépendances : on a « perdu » $me \rightarrow p$.

Preuve de l'algorithme : rappels

La clôture préserve les inclusions : si $X \subseteq Y$ alors $X^+ \subseteq Y^+$.

Théorème de décomposition : soit A un ensemble d'attributs.

Soient $R_1 = R[A^+]$ et $R_2 = R[A \cup (S - A^+)]$, alors :

- Les attributs communs à R_1 et R_2 sont exactement les attributs de A .
- $R[A] = R_1[A] = R_2[A]$.
- A est une superclé pour R_1 .
- $R_1 = R$ si seulement si $A^+ = S$.
- $R_2 = R$ si seulement si $A^+ = A$.

De plus, $R = R_1 * R_2$.

Preuve de l'algorithme : terminaison

En cas de récursion (-B-), les appels se font avec S_1 et S_2 qui **sont strictement inclus dans S**

En effet dans ce cas, on a $A^+ \subsetneq S$ (par hypothèse) et $A \subsetneq A^+$ (car $A \rightarrow b$ est une dépendance singleton).

Et donc S_1 et S_2 sont strictement inclus dans S , d'après le théorème de décomposition.

Preuve de l'algorithme : correction (1/6)

But : On doit prouver que l'algorithme calcule **une décomposition de R qui est BCNF et qui évite les redondances**.

Nous démontrons ce résultat par une **récurrence** structurelle.

Preuve de l'algorithme : correction (2/6)

Supposons que **le test en T est faux** : $\forall A \rightarrow b \in \mathcal{D}, A^+ = S$. Soit C un ensemble d'attributs de R .

- S'il existe $A \rightarrow b$ dans \mathcal{D} avec $A \subseteq C$, alors $A^+ \subseteq C^+$, puisque la clôture préserve les inclusions, donc $C^+ = S$.
- Sinon, $C^+ = C$, d'après l'algorithme de clôture.

Ainsi R est BCNF. Or, $Res = \{S\}$ et $R[S] = R$.

Donc, on obtient une décomposition BCNF de R .

Bien sûr cette décomposition évite les redondances.

Preuve de l'algorithme : correction (3/6)

Supposons maintenant que le test en T est vrai pour une dépendance $A \rightarrow b$.

On a alors en entrée de (B) un ensemble d'attributs A tel que $A^+ \not\subseteq S$, et en sortie $Res = Res_1 \cup Res_2$.

Posons $Res_1 = \{S_1^1 \dots S_1^n\}$ et $Res_2 = \{S_2^1 \dots S_2^m\}$.

Par hypothèse de récurrence :

- Les relations $R[S_1^1], \dots, R[S_1^n]$ sont toutes BCNF, $R_1 = R[S_1^1] * \dots * R[S_1^n]$, et $\forall i, j \in \{1 \dots n\}, (i \neq j) \Rightarrow (S_1^i \not\subseteq S_1^j)$.
- Les relations $R[S_2^1], \dots, R[S_2^m]$ sont toutes BCNF, $R_2 = R[S_2^1] * \dots * R[S_2^m]$ et $\forall i, j \in \{1 \dots m\}, (i \neq j) \Rightarrow (S_2^i \not\subseteq S_2^j)$.

Montrons d'abord qu'on obtient une décomposition BCNF de R .

- On a $Res = Res_1 \cup Res_2$.
Donc, par l'hypothèse de récurrence, $\forall X \in Res, R[X]$ est BCNF.
- De plus, d'après le théorème de décomposition, on a $R = R_1 * R_2 = R[S_1^1] * \dots * R[S_1^n] * R[S_2^1] * \dots * R[S_2^m]$.

Par conséquent, on obtient bien une décomposition BCNF de R .

Preuve de l'algorithme : correction (5/6)

Montrons que $S_1^i \cap S_2^j \subseteq A$

Puisque $S_1^i \subseteq S_1$ et $S_2^j \subseteq S_2$, on a $S_1^i \cap S_2^j \subseteq S_1 \cap S_2$.

Or, d'après le théorème de décomposition $S_1 \cap S_2 = A$.

D'où $S_1^i \cap S_2^j \subseteq A$.

Preuve de l'algorithme : correction (4/6)

Montrons maintenant que cette décomposition évite les redondances.

D'après l'hypothèse de récurrence, il reste à montrer que quels que soient $S_1^i \in Res_1$ et $S_2^j \in Res_2$, on a $S_1^i \not\subseteq S_2^j$ et $S_2^j \not\subseteq S_1^i$, ce qui équivaut à $S_1^i \cap S_2^j \neq S_1^i$ et $S_1^i \cap S_2^j \neq S_2^j$.

Pour cela, on va montrer

- d'une part que $S_1^i \cap S_2^j \subseteq A$ et
- d'autre part que $S_1^i \not\subseteq A$ et $S_2^j \not\subseteq A$.

Preuve de l'algorithme : correction (6/6)

Montrons que $S_1^i \not\subseteq A$

(la preuve de $S_2^j \not\subseteq A$ est analogue)

L'ensemble d'attributs S_1^i est obtenu lors d'un appel récursif avec R' , S' et \mathcal{D}' , suite à la découverte d'une dépendance singleton $A' \rightarrow b'$ dans \mathcal{D}' , telle que $A'^+ \not\subseteq S'$ (on peut avoir $A' = A$).

D'après le théorème de décomposition, on a $A' \subseteq S_1^i$.

De plus, d'une part $A' \not\subseteq A'^+$ car $b \notin A'$ ($A' \rightarrow b'$ est singleton) et d'autre part, $S' - A'^+ \neq \emptyset$ ($A'^+ \not\subseteq S'$)

D'où, $A' \not\subseteq S_1^i$.

Puisque les dépendances fonctionnelles sont choisies en respectant l'ordre croissant de cardinal du membre gauche, on a $|A'| \geq |A|$, et donc, soit $A' = A$ soit $A' \not\subseteq A$.

- Si $A' = A$, alors $A' \not\subseteq S_1^i$ signifie $A \not\subseteq S_1^i$, donc $S_1^i \not\subseteq A$
- Si $A' \not\subseteq A$, alors $S_1^i \not\subseteq A$ puisque $A' \not\subseteq S_1^i$.

Donc, dans tous les cas, on a $S_1^i \not\subseteq A$.

Principe

L'algorithme de synthèse calcule une **décomposition BCNF avec préservation des dépendances**.

Mais en général il retourne **un résultat qui comporte des redondances**.

Il est fondé sur la notion de **base minimale**.

Base minimale

Une base de dépendances fonctionnelles \mathcal{D} est **minimale** si elle est formée de **dépendances fonctionnelles singletons** et si :

- Aucune dépendance fonctionnelle de \mathcal{D} n'est conséquence des autres dépendances fonctionnelles de \mathcal{D} .
- Pour chaque dépendance fonctionnelle $a_1 \dots a_n \rightarrow b$ de \mathcal{D} (avec $n \geq 2$) et chaque $i \in \{1, \dots, n\}$, la dépendance fonctionnelle $a_1 \dots \cancel{a_i} \dots a_n \rightarrow b$ n'est pas conséquence de \mathcal{D}

(on dit alors que la dépendance fonctionnelle $a_1 \dots a_n \rightarrow b$ de \mathcal{D} est **élémentaire**).

Algorithme de détermination d'une base minimale

Entrée. Une base \mathcal{D} de dépendances fonctionnelles singletons.

Sortie. Une base \mathcal{D}_{min} minimale de dépendances fonctionnelles.

Principe. « Nettoyer » \mathcal{D} .

-I- Initialiser \mathcal{D}_{min} à \mathcal{D} .

-B- Exécuter B1 et B2, dans n'importe quel ordre, jusqu'à ce que \mathcal{D}_{min} ne puisse plus être modifiée :

-B1- **Si** $a_1 \dots a_n \rightarrow b$ dans \mathcal{D}_{min} est conséquence des autres dépendances fonctionnelles de \mathcal{D}_{min} ,
alors enlever $a_1 \dots a_n \rightarrow b$ de \mathcal{D}_{min} .

-B2- **Si** $a_1 \dots \cancel{a_i} \dots a_n \rightarrow b$ est conséquence de \mathcal{D}_{min} ,

pour un $a_1 \dots a_n \rightarrow b$ dans \mathcal{D}_{min} (avec $n \geq 2$) et un i entre 1 et n ,
alors remplacer $a_1 \dots a_n \rightarrow b$ par $a_1 \dots \cancel{a_i} \dots a_n \rightarrow b$ dans \mathcal{D}_{min} .

-RET- Retourner \mathcal{D}_{min} .

B1 : détail

Pour tester si $A \rightarrow b$ dans \mathcal{D}_{min} est **conséquence des autres dépendances fonctionnelles de \mathcal{D}_{min}** :

On note \mathcal{D}' l'ensemble de dépendances fonctionnelles obtenu en **retirant $A \rightarrow b$ de \mathcal{D}_{min}** .

On calcule A^+ (**la clôture de A relativement à \mathcal{D}'**).

La réponse est **oui** si et seulement si $b \in A^+$.

Si la réponse est **oui**, alors **on retire $A \rightarrow b$ de \mathcal{D}_{min}** .

B2 : détail

Pour tester si $A \rightarrow b$, où $A = a_1 \dots \cancel{a_i} \dots a_n$, est conséquence de \mathcal{D}_{min} :

On calcule A^+ (la clôture de A) relativement à \mathcal{D}_{min} .

La réponse est **oui** si et seulement si $b \in A^+$.

Si la réponse est **oui**, alors **on remplace** $a_1 \dots a_n \rightarrow b$ par $a_1 \dots \cancel{a_i} \dots a_n \rightarrow b$ dans \mathcal{D}_{min} .

Exemples (1/3)

Soit $R(a, b, c)$ avec la base de dépendances fonctionnelles $\{ab \rightarrow c, a \rightarrow b\}$.

On ne peut pas appliquer B1. Par exemple, $a^+ = a$ relativement à $\{ab \rightarrow c\}$.

On peut appliquer B2 pour réduire $ab \rightarrow c$ en $a \rightarrow c$ car $a^+ = abc$ relativement à $\{ab \rightarrow c, a \rightarrow b\}$.

Ainsi, on obtient la **base minimale** $\{a \rightarrow c, a \rightarrow b\}$.

Exemples (2/3)

Soit $R(a, b, c, d, e)$ avec la base de dépendances fonctionnelles $\{a \rightarrow b, a \rightarrow d, b \rightarrow d, b \rightarrow e, de \rightarrow c, ae \rightarrow c\}$.

On peut appliquer B1 : $a \rightarrow d$ est conséquence de $\{a \rightarrow b, b \rightarrow d, b \rightarrow e, de \rightarrow c, ae \rightarrow c\}$. En effet, $a^+ = abdec$ relativement à $\{a \rightarrow b, b \rightarrow d, b \rightarrow e, de \rightarrow c, ae \rightarrow c\}$. (d'ailleurs, a est une clé !)

On réduit donc la base à $\{a \rightarrow b, b \rightarrow d, b \rightarrow e, de \rightarrow c, ae \rightarrow c\}$.

On peut encore appliquer B1 : $ae \rightarrow c$ est conséquence de $\{a \rightarrow b, b \rightarrow d, b \rightarrow e, de \rightarrow c\}$. En effet, $ae^+ = abdec$ relativement à $\{a \rightarrow b, b \rightarrow d, b \rightarrow e, de \rightarrow c\}$ (d'ailleurs, ae est une clé !)

On réduit donc la base à $\{a \rightarrow b, b \rightarrow d, b \rightarrow e, de \rightarrow c\}$.

On ne peut plus appliquer B1

On ne peut pas appliquer B2

Ainsi, on obtient la **base minimale** $\{a \rightarrow b, b \rightarrow d, b \rightarrow e, de \rightarrow c\}$.

Exemples : ADE (3/3)

Soit la relation $R(c, p, h, s, e, n)$ où les attributs signifient :

c	Cours
p	Professeur
h	Heure
s	Salle
e	Etudiant
n	Note

avec une base de dépendances fonctionnelles :

$c \rightarrow p$	Chaque cours a un professeur
$hs \rightarrow c$	Il y a (au plus) un cours pour une heure et une salle donnés
$hp \rightarrow cs$	Il y a (au plus) un cours et (au plus) une salle pour une heure et un professeur donnés
$he \rightarrow cs$	Il y a (au plus) un cours et (au plus) une salle pour une heure et un étudiant donnés
$ce \rightarrow n$	Un étudiant n'a qu'une note par cours.

Exemples : ADE (3/3)

On considère la base de dépendances fonctionnelles singletons équivalentes :

$$\mathcal{D}_{min} = \{c \rightarrow p, hs \rightarrow c, hp \rightarrow c, he \rightarrow c, hp \rightarrow s, he \rightarrow s, ce \rightarrow n\}$$

On peut appliquer B1 :

- On peut enlever $hp \rightarrow c$ car $hp^+ = hpsc$ relativement à $\mathcal{D}_{min} - \{hp \rightarrow c\}$. Donc, \mathcal{D}_{min} devient $\{c \rightarrow p, hs \rightarrow c, he \rightarrow c, hp \rightarrow s, he \rightarrow s, ce \rightarrow n\}$.
- On peut ensuite enlever $he \rightarrow c$ car $he^+ = hescpn$ relativement à $\mathcal{D}_{min} - \{he \rightarrow c\}$. Donc, \mathcal{D}_{min} devient $\{c \rightarrow p, hs \rightarrow c, hp \rightarrow s, he \rightarrow s, ce \rightarrow n\}$.

On ne peut plus appliquer B1

On ne peut pas appliquer B2

Ainsi, on obtient la base minimale

$$\{c \rightarrow p, hs \rightarrow c, hp \rightarrow s, he \rightarrow s, ce \rightarrow n\}.$$

Preuve de l'algorithme : correction B1

Considérons un pas de B1 qui modifie \mathcal{D}_{min} .

Notons \mathcal{D}_A et \mathcal{D}_B les deux valeurs successives de l'ensemble courant \mathcal{D}_{min} : on passe de \mathcal{D}_A à \mathcal{D}_B

Soit $A \rightarrow b$ la dépendance fonctionnelle supprimée lors du pas.

Par définition, $\mathcal{D}_B \subsetneq \mathcal{D}_A$. Donc, $\mathcal{D}_A \Rightarrow \mathcal{D}_B$.

D'après l'algorithme, $\mathcal{D}_B \Rightarrow \{A \rightarrow b\}$. Donc

$$\mathcal{D}_B \Rightarrow \mathcal{D}_B \cup \{A \rightarrow b\} = \mathcal{D}_A. \text{ D'où, } \mathcal{D}_B \Rightarrow \mathcal{D}_A.$$

Ainsi, $\mathcal{D}_A \Leftrightarrow \mathcal{D}_B$.

Preuve de l'algorithme : terminaison

La somme du nombre d'attributs dans les membres gauches des dépendances fonctionnelles décroît strictement à chaque pas.

Preuve de l'algorithme : correction B2

Considérons un pas de B2 qui modifie \mathcal{D}_{min} .

Notons $A = a_1 \dots a_n$ et $B = a_1 \dots \cancel{a_j} \dots a_n$, notons \mathcal{D}_A et \mathcal{D}_B les deux valeurs successives de l'ensemble courant \mathcal{D}_{min} : on passe de \mathcal{D}_A à \mathcal{D}_B en remplaçant $A \rightarrow b$ par $B \rightarrow b$.

Autrement dit, en notant \mathcal{D}' l'ensemble \mathcal{D}_A privé de $A \rightarrow b$, on a $\mathcal{D}_A = \mathcal{D}' \cup \{A \rightarrow b\}$ et $\mathcal{D}_B = \mathcal{D}' \cup \{B \rightarrow b\}$.

Donc, $\mathcal{D}_A \Rightarrow \mathcal{D}'$ et $\mathcal{D}_B \Rightarrow \mathcal{D}'$.

- $B \rightarrow b$ est conséquence de \mathcal{D}_A par hypothèse et $\mathcal{D}_A \Rightarrow \mathcal{D}'$, donc $\mathcal{D}_A \Rightarrow \mathcal{D}_B$.
- $A \rightarrow b$ est conséquence de $B \rightarrow b$ car $B \subseteq A$, donc, par réflexivité $A \rightarrow B$ et par transitivité, on a $A \rightarrow B$ et $B \rightarrow b$ qui donne $A \rightarrow b$.
Donc $A \rightarrow b$ est conséquence de \mathcal{D}_B et $\mathcal{D}_B \Rightarrow \mathcal{D}'$ donnent $\mathcal{D}_B \Rightarrow \mathcal{D}_A$.

Ainsi, $\mathcal{D}_A \Leftrightarrow \mathcal{D}_B$.

Algorithme de synthèse BCNF

Entrée. Une base minimale \mathcal{D}_{min} de R .

(\mathcal{D}_{min} peut être obtenue par l'algorithme de détermination d'un ensemble de dépendances fonctionnelles minimal).

Sortie. $Res = \{S_1, \dots, S_n\}$ où les S_i fournissent des relations formant une décomposition de R en BCNF qui **préserve les dépendances** (mais **n'évite pas toujours les redondances**).

-I- Poser $Res = \emptyset$

-U- (UNION) Pour **chaque partie gauche** A d'une dépendance fonctionnelle de \mathcal{D}_{min} :

Soit B l'ensemble de tous les attributs b tels que $A \rightarrow b$ est dans \mathcal{D}_{min} .

Ajouter $A \cup B$ dans Res .

Cela donne une relation $R[A \cup B]$ avec les dépendances $\{A \rightarrow b : b \in B\}$.

-F- Si aucun des ensembles d'attributs dans Res **n'est une superclé** de R , alors :

Déterminer une clé K de R et ajouter K dans Res .

Cela donne une relation $R[K]$ sans dépendance fonctionnelle.

-RET- Retourner Res .

Algorithme de synthèse BCNF (suite)

Détails. Pour la partie F, si on ne connaît pas les clés de R , on peut procéder comme suit :

Calculer la clôture de chacun des S_i dans Res .

S'il y a un i tel que $S_i^+ = S$, alors la décomposition est terminée.

Sinon, calculer un clé de R en utilisant l'algorithme de calcul des clôtures d'attributs et en s'arrêtant dès que la première clé est obtenue.

Exemples (1/6)

Soit $R(a, b)$ avec la base $\{a \rightarrow b, b \rightarrow a\}$.

On a déjà vu que R est en BCNF : R a deux clés (a) et (b), et la base donnée est minimale.

L'algorithme de synthèse fournit la décomposition BCNF

$R = R[\underline{a}, b] * R[b, \underline{a}]$, où $\{a \rightarrow b\}$ est la base de $R[\underline{a}, b]$ et $\{b \rightarrow a\}$ est la base de $R[b, \underline{a}]$.

(N.b., il n'est pas nécessaire d'ajouter une autre relation car ab est superclé de R .)

Cette décomposition bien sûr est redondante : $R[\underline{a}, b] = R[b, \underline{a}]$.

Exemples (2/6)

Soit $R(l, o, s, b)$ avec la base $\{l \rightarrow os, s \rightarrow b\}$ ou $\{l \rightarrow o, l \rightarrow s, s \rightarrow b\}$.



Exemples (3/6)

Soit $R(l, o, s, b)$ avec la base $\{l \rightarrow os, s \rightarrow b, o \rightarrow b\}$ ou $\{l \rightarrow o, l \rightarrow s, s \rightarrow b, o \rightarrow b\}$.

La base donnée est minimale donc l'algorithme de synthèse donne la décomposition $R = R[l, o, s] * R[s, b] * R[o, b]$, où $\{l \rightarrow o, l \rightarrow s\}$ est la base de $R[l, o, s]$, $\{s \rightarrow b\}$ est la base de $R[s, b]$, et $\{o \rightarrow b\}$ est la base de $R[o, b]$.

(N.b., il n'est pas nécessaire d'ajouter une autre relation car los est superclé de R .)

Cette décomposition n'est pas redondante.

Rappel : l'algorithme récursif BCNF donne $R = R[l, o, s] * R[s, b]$ ou $R = R[l, o, s] * R[o, b]$, qui ne préservent pas les dépendances (soit $o \rightarrow b$, soit $s \rightarrow b$ est perdue).

Exemples (5/6)

Soit $R(c, p, h, s, e, n)$ avec la base minimale $\{c \rightarrow p, hs \rightarrow c, hp \rightarrow s, he \rightarrow s, ce \rightarrow n\}$ calculée précédemment.

L'algorithme de synthèse donne la décomposition $R = R[c, p] * R[h, s, c] * R[h, p, s] * R[h, e, s] * R[c, e, n]$, où

- $\{c \rightarrow p\}$ est la base de $R[c, p]$,
- $\{hs \rightarrow c\}$ est la base de $R[h, s, c]$,
- $\{hp \rightarrow s\}$ est la base de $R[h, p, s]$,
- $\{he \rightarrow s\}$ est la base de $R[h, e, s]$ et
- $\{ce \rightarrow n\}$ est la base de $R[c, e, n]$.

(N.b., il n'est pas nécessaire d'ajouter une autre relation car hes est superclé de R .)

Cette décomposition évite les redondances.

Exemples (4/6)

Soit $R(p, m, e)$ avec la base $\{p \rightarrow m, me \rightarrow p\}$.

La base donnée est minimale donc l'algorithme de synthèse donne la décomposition $R = R[p, m] * R[m, e, p]$, où $\{p \rightarrow m\}$ est la base de $R[p, m]$ et $\{me \rightarrow p\}$ est la base de $R[m, e, p]$.
(N.b., il n'est pas nécessaire d'ajouter une autre relation car mep est superclé de R .)

Cette décomposition est redondante car $\{pm\} \subseteq \{mep\}$: en fait la seconde relation est exactement R .

Rappel : l'algorithme récursif BCNF donne $R = R[p, m] * R[p, e]$, qui ne préserve pas la dépendance $me \rightarrow p$.

Exemples (6/6)

Soit $R(p, h, s, e)$ avec la base minimale $\{hp \rightarrow s\}$.

Bien sûr, cette base est minimale. L'algorithme de synthèse fournit d'abord $R[h, p, s]$, où $\{hp \rightarrow s\}$ est la base de $R[h, p, s]$.

Et comme aucune clé de R n'est dans phs , on doit ajouter une relation.

L'unique clé de R est phe .

Donc on obtient la décomposition BCNF préservant les dépendances : $R = R[h, p, s] * R[p, h, e]$, où $\{hp \rightarrow s\}$ est la base de $R[h, p, s]$ et \emptyset est la base de $R[p, h, e]$.

Cette décomposition évite les redondances.

Preuve de l'algorithme : terminaison

-I- : **temps constant**.

-U- : **Polynomial en $|\mathcal{D}_{min}| * |S|$** .

-F- : Il y a $2^{|S|} - 1$ sous-ensembles non-vides de S . Pour déterminer une clé ou l'absence de superclé, il faut calculer les clôtures de toute ou partie de ces sous-ensembles, chaque clôture a un coût polynomial en $|\mathcal{D}_{min}| * |S|$. D'où, une complexité **finie mais exponentielle** ($\leq e^{O(|\mathcal{D}_{min}| * |S|)}$).

-RET- : **temps constant**.

Preuve de l'algorithme : correction (1/3)

Rappel : on pose $Res = \{S_1, \dots, S_n\}$ à la fin de l'algorithme.

Notons $\mathcal{D}_{min}^{S_i} \subseteq \mathcal{D}_{min}$ l'ensemble des dépendances fonctionnelles de $R[S_i]$.

À la fin de U, on a $Res = \{S_1, \dots, S_x\}$ avec $x \in \{n-1, n\}$.

Tout d'abord, par construction, **il n'y pas de perte de dépendances fonctionnelles** : $\forall A \rightarrow b \in \mathcal{D}_{min}, \exists i \in \{1, \dots, x\}$ tel que $A \cup \{b\} \in S_i$.

Ensuite, **tout élément de $S - (S_1 \cup \dots \cup S_x)$** n'apparaît dans aucune dépendance fonctionnelle de \mathcal{D}_{min} , donc **appartient** à toute clé de R et donc **à toute superclé de R** .

Donc, par F, $S - (S_1 \cup \dots \cup S_n)$ est nécessairement vide.

Ainsi, on peut conclure que $S_1 \cup \dots \cup S_n = S$, donc

$R \subseteq R[S_1] * \dots * R[S_n]$.

Preuve de l'algorithme : correction (2/3)

Toujours d'après F, il existe $S_i \in Res$ tel que S_i est une superclé de R .

Or, $R[S_1] * \dots * R[S_n]$ et R ont les mêmes dépendances fonctionnelles (il n'y a pas de pertes) et les mêmes attributs ($S_1 \cup \dots \cup S_n = S$).

Donc S_i est une superclé de $R[S_1] * \dots * R[S_n]$. Donc,

$|R[S_1] * \dots * R[S_n]| = |R[S_i]| \leq |R|$.

Puisque $R \subseteq R[S_1] * \dots * R[S_n]$ et $|R[S_1] * \dots * R[S_n]| \leq |R|$, on a $R = R[S_1] * \dots * R[S_n]$, c'est-à-dire, $R[S_1], \dots, R[S_n]$ est une **décomposition de R** .

Preuve de l'algorithme : correction (3/3)

Par construction, **après U mais avant F**, $\forall i \in \{1, \dots, x\}$, $R[S_i]$ a **au moins une dépendance fonctionnelle** et pour la dépendance fonctionnelle $A \rightarrow b$ de $R[S_i]$, A est superclé de $R[S_i]$.

Pour **ensemble d'attributs X de $R[S_i]$** , si **aucun sous-ensemble de X n'est partie gauche de la dépendance fonctionnelle de $R[S_i]$** , alors

$X^+ = X$ relativement à $\mathcal{D}_{min}^{S_i}$;

sinon $X^+ = S_i$ relativement à $\mathcal{D}_{min}^{S_i}$. (d'après l'algorithme de clôture)

Si F modifie Res , on a en plus $R[K]$ sans dépendance fonctionnelle.

Donc pour tout sous-ensemble X de K (c'est-à-dire, tout sous-ensemble d'attributs de $R[K]$), on a $X^+ = X$ relativement à \mathcal{D}_{min}^K .

Ainsi, $\forall i \in \{1, \dots, n\}$, $R[S_i]$ est BCNF.