

Théorie de la Normalisation

1/44


La phase de design d'une BD

- ❑ Analyse des besoins
- ❑ Design conceptuel
 - ❑ Modèle EA, UML
- ❑ Design logique
 - ❑ EA vers relations
 - ❑ raffinement de schéma: normalisation
- ❑ Design physique
 - ❑ indexes, etc.


2/44

Conception de schéma


Modèle conceptuel:



Modèle relationnel +
DFs



Normalisation:
Éliminer les anomalies



3/44

Théorie de la normalisation

- Anomalies de conception, redondance
- Dépendances fonctionnelles
- Décomposition de schéma
- Formes normales
- Automatisation de la normalisation
- Conclusion

4/44

Anomalies de conception de schéma

VOITURE (N°VEH, TYPE, COULEUR, MARQUE, PUISSANCE)

Un **type** de voiture peut avoir une seule **puissance** et une seule **marque**, mais différentes couleurs, numéros

VOITURE	NVH	MARQUE	TYPE	PUIS	COULEUR
	872RH7	RENAULT	R21	7	BLEUE
	975AB8	RENAULT	R21	7	BEIGE
	975AB8	PEUGEOT	205	8	ROUGE

Redondance, anomalies de modification, anomalies d'effacement.

5/44

Décomposition

VOITURE	NVH	MARQUE	TYPE	PUIS	COULEUR
	872RH7	RENAULT	R21	7	BLEUE
	975AB8	RENAULT	R21	7	BEIGE
	975AB8	PEUGEOT	205	8	ROUGE

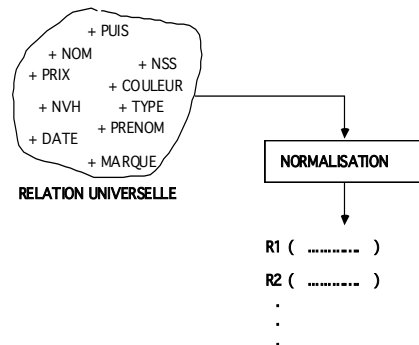
V_TYPE	MARQUE	TYPE	PUIS
	RENAULT	R21	7
	PEUGEOT	205	8

V_NVH	NVH	TYPE	COULEUR
	872RH7	R21	BLEUE
	975AB8	R21	BEIGE
	975AB8	205	ROUGE

6/44

Objectif et principes

- ❑ Problèmes de conception: redondances et anomalies de m.à.j.
- ❑ Objectif : Minimiser les redondances pour améliorer les performance de la BD.
 - ▶ requêtes d'interrogation et de mise à jour plus rapides
 - ▶ moins de valeurs NULL
 - ▶ gestion de l'intégrité des données simplifiée
- ❑ Principe :



7/44

Dépendances fonctionnelles

❑ Définition :

$X \twoheadrightarrow Y$, X détermine Y , ou Y dépend fonctionnellement de X ,

X et Y : ensembles d'attributs de R

est une assertion sur toutes les instances de la relation R telle que si deux tuples quelconques de R possèdent la même valeur sur X , alors ils doivent avoir la même valeur sur Y .

Formellement :

$X \twoheadrightarrow Y$ ssi quel que soit l'instance r de R , pour tout tuple $t1$ et $t2$ de r on a :

$$\Pi_X(t1) = \Pi_X(t2) \implies \Pi_Y(t1) = \Pi_Y(t2)$$

Utilité :

Contrainte sur les données que peut contenir la relation.

Outil de contrôle d'intégrité des données (niveau schéma).

Outil mathématique permettant d'expliquer le processus de la « normalisation »

Vital lorsqu'on veut ré-étudier le schéma d'une BD qui pose problème.

8/44

Dépendances fonctionnelles

Definition: $A_1, \dots, A_m \rightarrow B_1, \dots, B_n$ vérifiée dans R si:

$\forall t, t' \in R, (t.A_1=t'.A_1 \wedge \dots \wedge t.A_m=t'.A_m \Rightarrow t.B_1=t'.B_1 \wedge \dots \wedge t.B_n=t'.B_n)$

R

	A_1	...	A_m		B_1	...	B_m		
t									
t'									

si t, t' ont les mêmes valeurs ici
 alors t, t' ont les mêmes valeurs ici aussi

9/44

Exemples

ID	Nom	Tél	Dép
I0	S	1234	Info
I3	M	9876	Ventes
I1	S	9876	Ventes
I9	M	1234	RH

ID -> Nom, Tél, Dép ?

Dép -> Tél ?

Tél -> Dép ?

10/44

Observation

Si ces deux DFs vérifiées:

nom -> couleur
couleur, catégorie -> prix

Alors cette DF vérifiée aussi:

nom, catégorie -> prix

Explication?

11/44

Axiomes d'Armstrong

□ Propriétés de base

Réflexivité

Y inclus dans X $\Rightarrow X \rightarrow Y$

Augmentation

$X \rightarrow Y \Rightarrow XZ \rightarrow YZ$

Transitivité

$X \rightarrow Y$ et $Y \rightarrow Z \Rightarrow X \rightarrow Z$

□ Propriétés déduites

Union

$X \rightarrow Y$
 $X \rightarrow Z \Rightarrow X \rightarrow YZ$

Pseudo-transitivité

$X \rightarrow Y$
 $YW \rightarrow Z \Rightarrow XW \rightarrow Z$

Décomposition

$X \rightarrow Y$
 Z inclus dans Y
 $\Rightarrow X \rightarrow Z$

12/44

F^+ et Couverture minimale

- ❑ Fermeture transitive d'un ensemble F de DF
 - ❑ $F^+ = F \cup \{DF \text{ déduites de celles contenues dans } F\}$
- ❑ Couverture minimale d'un ensemble F de DF
 - ❑ Sous-ensemble minimum de DF **élémentaires** permettant de générer toutes les autres.
 - ❑ **Théorème** : tout ensemble de DF possède une couverture minimale, en général non unique.
 - ❑ Formellement, F est une CM ssi :
 - ❑ Tout f dans F est élémentaire.
 - ❑ Il n'existe pas de f dans F telle que $F - \{f\}$ soit « équivalent » à F .
- ❑ DF élémentaires (les seules utiles)
 - ❑ Une **DF élémentaire** est une DF de la forme $X \rightarrow A$, où :
 - ❑ A est un attribut, X un ensemble d'attributs, **A n'est pas inclus dans X**
 - ❑ **il n'existe pas X' inclus dans X tel que $X' \rightarrow A$ dans F^+**
- ❑ Equivalence
 - ❑ On dit que deux ensembles de DF sont équivalents s'ils possèdent la même fermeture transitive.

13/44

Calcul de F^+

- ❑ Avec les axiomes de Armstrong
 - ❑ **Trop compliqué!**

14/44

X^+ : Fermeture d'un ensemble d'attributs X

Pour $X = A_1, \dots, A_n$

La **fermeture**, $\{A_1, \dots, A_n\}^+ =$ l'ensemble des attributs B
t.q. $A_1, \dots, A_n \rightarrow B$

Exemple:

nom \rightarrow couleur
catégorie \rightarrow département
couleur, catégorie \rightarrow prix

Fermetures:

nom⁺ = {nom, couleur}

{nom, catégorie}⁺ = {nom, catégorie, couleur, département, prix}

couleur⁺ = {couleur}

15/44

Calcul de X^+

$X^+ := X$

do{

pour chaque DF $Y \rightarrow Z$ dans F tq

Y inclus dans X^+

$X^+ := X^+ + Z$

}

until (X^+ inchangé)

{nom, catégorie}⁺ = {nom, catégorie, couleur, département, prix}

nom, catégorie \rightarrow couleur, département, prix

16/44

Tester l'appartenance d'une DF à F^+

- ❑ Les axiomes d'Armstrong: correctes et complètes (calculent F^+)
- ❑ Pour tester l'appartenance de $X \rightarrow Y$ à F^+ :
 - ❑ calculer la fermeture de X , $X^+ = \{A_i \mid X \rightarrow A_i\}$
 - ❑ tester si Y inclus dans X^+

F^+ : Énumérer les DFs $X \rightarrow Y$ t.q. $Y \subseteq X^+$ et $X \cap Y = \emptyset$

17/44


Clé d'une relation

- ❑ Définition :
 - Ensemble minimum d'attributs qui détermine tous les autres.**
- ❑ Formellement :
 - Soient : $R(A_1, A_2, \dots, A_n)$ un schéma de relation, F^+ l'ensemble des DF associés et X un sous-ensemble de A_1, A_2, \dots, A_n .
 - X est une clé de R ssi :
 - ❑ $X \rightarrow A_1 A_2 \dots A_n$ est dans F^+
 - ❑ il n'existe pas de sous-ensemble X' inclus dans X tel que $X' \rightarrow A_1 A_2 \dots A_n$
- ❑ Non unicité :
 - ❑ Il peut y avoir plusieurs clés pour une relation (clés candidates)
 - ❑ Une est choisie comme clé primaire
- ❑ Sur-clé :
 - ❑ Sur-clé : X est sur-clé ssi $X \rightarrow R$ dans F^+

18/44

Grappe des DF

VOITURE (N°VEH, TYPE, COULEUR, MARQUE, PUISSANCE)




19/44

Autre Exemple

CRU	TYPE	CLIENT	REMISE
CHENAS	A	C1	3%
MEDOC	A	C2	5%
JULIENAS	B	C1	4%

CRU --> TYPE
TYPE, CLIENT --> REMISE



20/44

Calculer les (sur)clés

- ❑ Calculer X^+ pour tous les ensemble X
- ❑ Si $X^+ = \{\text{tous les attributs}\}$, alors X est une (sur)clé
- ❑ Lister uniquement les X s minimaux

Les clés décident la «qualité» d' un schéma.

21/44

Décomposition de schéma

Définition :

La décomposition d'un schéma de relation $R(A_1, \dots, A_n)$ consiste en son remplacement par une collection de relations (R_1, \dots, R_m) tel que

$$\text{SCHEM}(R) = \text{SCHEM}(R_1) \cup \text{SCHEM}(R_2) \cup \dots \cup \text{SCHEM}(R_m)$$

But de la décomposition :

Casser R en de plus petites relations afin d'éviter :

les redondances

les anomalies en mises à jour

22/44

Décomposition Sans Perte d'Information

Définition

Une décomposition d'une relation R en m relation (R_1, \dots, R_m) est SPI par rapport à un ensemble de DF si et seulement si, quelle que soit I une instance de R , alors

$$I = I_1 \times I_2 \times \dots \times I_m$$

$$\text{où } I_j = \Pi_{R_j}(I)$$

c-à-d, Il doit exister une série de jointures sur les instances de R_1, \dots, R_m qui permet de reconstruire I .

Théorème:

Une décomposition de R en R_1 et R_2 est SPI ssi $R_1 \cap R_2$ est sur-clé de R_1 et/ou R_2 .

23/44

Décomposition Sans Perte d'Information

Preuve :

On cherche à démontrer que $\Pi_{R_1}(r) \times \Pi_{R_2}(r) = r$.

❖ $r \subseteq \Pi_{R_1}(r) \times \Pi_{R_2}(r)$ est toujours vrai.

Soient r :

A	B	C
a1	b1	c1
a2	b2	c2
a3	b1	c3

$\Pi_{R_1}(r)$:

A	B
a1	b1
a2	b2
a3	b1

$\Pi_{R_2}(r)$:

B	C
b1	c1
b2	c2
b1	c3

$\Pi_{R_1}(r) \times \Pi_{R_2}(r)$:

A	B	C
a1	b1	c1
a1	b1	c3
a2	b2	c2
a3	b1	c1
a3	b1	c3

24/44

Décomposition Sans Perte d'Information

Preuve :

On cherche à démontrer que $\Pi_{R_1}(r) \times \Pi_{R_2}(r) = r$.

❖ $\Pi_{R_1}(r) \times \Pi_{R_2}(r) \subseteq r$ n'est en général pas vrai.

Si $\exists t \in \Pi_{R_1}(r) \times \Pi_{R_2}(r)$ et $t \notin r$

⇒ **$R_1 \cap R_2$ n'est pas sur-clé, ni de R_1 ni de R_2 .**


25/44

Exemple

VOITURE	NVH	MARQUE	TYPE	PUIS	COULEUR
	872RH75	RENAULT	R21	7	BLEUE
	975AB80	RENAULT	R21	7	BEIGE

R1	R2
8H75 R21 BLEUE	R21 RENAULT 7
97AB80 R21 BEIGE	

VOITURE = R1 X R2



R'1	R2	R'3
872RH75 R21	R21 7 BLEUE	R21 RENAULT
975AB80 R21	R21 7 BEIGE	

VOITURE \Leftrightarrow R'1 X R'2 X R'3

R'1 X R'2 X R'3

872RH75	R21	7	BLEUE	RENAULT
872RH75	R21	7	BEIGE	RENAULT
975AB80	R21	7	BLEUE	RENAULT
975AB80	R21	7	BEIGE	RENAULT

26/44

Décomposition sans perte de DF

Définition

Projection de F sur un sous-ensemble X d'attributs: l'ensemble de DFs dans F^+ qui utilisent uniquement X.

Définition

Une décomposition (R_1, \dots, R_m) de R préserve les DFs (SPD) si la fermeture transitive des DFs de R est la même que la fermeture transitive de l'union des projections des DFs sur R_1, \dots, R_m .

Exemple: $A \rightarrow B, B \rightarrow C, C \rightarrow A$ et la décomposition AB, BC

Tester si une décomposition est SPD: par la définition.

27/44

Exemple (1)

Exemple

1) $R_1(NVH, TYPE, COULEUR) \Rightarrow F_1 = \{ NVH \rightarrow TYPE, NVH \rightarrow COULEUR \}$

$R_2(TYPE, MARQUE, PUIS) \Rightarrow F_2 = \{ TYPE \rightarrow MARQUE, TYPE \rightarrow PUIS \}$

\Rightarrow OK

2) $R'_1(NVH, TYPE) \Rightarrow F'_1 = \{ NVH \rightarrow TYPE \}$

$R'_2(TYPE, PUIS, COULEUR) \Rightarrow F'_2 = \{ TYPE \rightarrow PUIS \}$

$R'_3(TYPE, MARQUE) \Rightarrow F'_3 = \{ TYPE \rightarrow MARQUE \}$

\Rightarrow ON A PERDU LA DF : $NVH \rightarrow COULEUR$

28/44

Exemple (2)


VOITURE (NVH, MARQUE, TYPE, PUIS, COULEUR)

VOITURE	NVH	MARQUE	TYPE	PUIS	COULEUR
	87 2RH75	RENAULT	R21	7	BLEUE
	97 5AB80	RENAULT	R21	7	BEIGE

R1 (NVH, TYPE, COULEUR)
R2 (TYPE, MARQUE, PUIS)

Décomposition

R'1 (NVH, TYPE)
R'2 (TYPE, PUIS, COULEUR)
R'3 (TYPE, MARQUE)



29/44

Formes normales pour éliminer les anomalies

Deux FN principales, BCNF et 3NF

Idée principale:

$X \rightarrow A$ est OK si X est un (sur)clé

sinon

$X \rightarrow A$ mauvaise (BCNF), à moins que A **prime** (3NF)

A prime: A appartient à une clé.

30/44

Formes normales

Définition 1NF

Une relation est en 1ère forme normale si tout attribut contient une valeur atomique (unique)

Exemple

PERSONNE	NOM	PROFESSION
	DUPONT	Ingénieur, Professeur
	MARTIN	Géomètre

Une telle relation doit être décomposée en répétant les noms pour chaque profession

31/44


2NF

Définition

une relation est en 2e forme normale ssi :

- elle est en 1ère forme
- tout attribut non clé ne dépend pas d'une partie de clé

Schéma



Une telle relation doit être décomposée en
 $R_1(\underline{K1}, \underline{K2}, X)$ et $R_2(\underline{K2}, Y)$

32/44

Exemple 2NF

❑ Exemple 1 :

- ❑ Fournisseur (nom, adresse, article, prix)
- ❑ La clé est (nom, article)
- ❑ Mais nom \rightarrow adresse : pas en 2e forme

❑ Exemple 2 :

- ❑ R (cru, type, client, remise)
- ❑ La clé est (cru, client)
- ❑ Mais cru \rightarrow type : pas en 2e forme

33/44


3NF

❑ Définition

❑ une relation est en 3e forme normale ssi :

- elle est en 1ère forme
- tout attribut n'appartenant pas à une clé ne dépend pas d'un ensemble d'attributs qui ne sont pas (sur)clé
- $X \rightarrow A$ une DF non triviale dans F^+ alors :
 - X contient une clé de R ou
 - A fait partie d'une clé de R (prime).

❑ Schéma



Une telle relation doit être décomposée en

$R_1(\underline{K}, X, Y)$ et $R_2(X, Z)$

34/44

Exemple 3ème Forme

❑ Exemple

❑ Voiture (nvh, marque, type, puissance, couleur)

❑ Type --> marque

❑ Type --> puissance

Pas en 3ème forme !

❑ Caractéristiques de la 3NF :

❑ redondance limitée

❑ On arrive toujours à une décomposition en 3NF SPI et SPD

35/44

Exemples de décomposition

❑ Voiture (nvh, marque, type, puissance, couleur)

véhicule (nvh, type, couleur)


Modèle (type, marque, puissance)

❑ Réduction (cru, type, client, remise)

Remise (Type, client, remise)

Type (cru, type)


Commande (Cru, Client)



36/44

Algorithme de décomposition

1. A partir du graphe G des DF, calculer une couverture minimale C
2. Rechercher le plus grand ensemble X d'attributs qui détermine d'autres attributs A1, ... An
 - Sans DF entre attributs : Ai->Aj
3. Editer la relation (X, A1, ... , An) qui est en 3FN
4. Supprimer les DFs (X->A1, ... X->An) du graphe de couverture minimale C
5. Supprimer les attributs isolés de C (i.e. les attributs non-cible ni source de DF)
6. Répéter l'opération de réduction du graphe C à partir de l'étape 2, jusqu'à ce que C soit vide.
7. Ajouter une relation dont les attributs forment une clé de la relation universelle



37/44

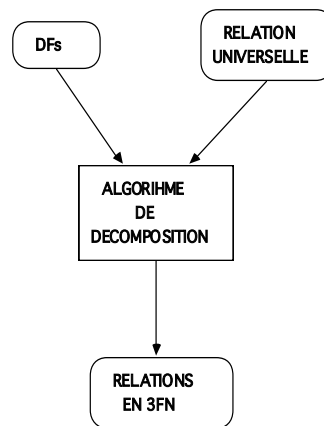
Comment tester si R en 3NF?

- Calcul des clés (les X^+)
- Pour chaque $X \rightarrow A$ dans F, par la définition
 - X (sur)clé ?
 - A prime?

38/44

Automatisation de la décomposition

**AUTOMATISATION DU
PROCESSUS DE DECOMPOSITION
EN 3NF, A PARTIR DE L'ENSEMBLE
DES ATTRIBUTS ET DES DFs**



39/44

Encore moins de redondances : BCNF

Définition:


une relation est en BCNF (Boyce-Codd Normal Form) ssi :
les seules dépendances fonctionnelles sont du type clé détermine attribut

$X \rightarrow A$ une DF non triviale dans F^+ alors :

➤ **X contient une clé de R**

Plus simple que 3NF, un peu plus fort, mais ne peut pas toujours être obtenue SPD !

$X^+ = \{X\}$ ou $X^+ = \text{tout}$



Une telle relation peut être décomposée en

$R_1(\underline{K2}, \underline{Y}, X)$ et $R_2(\underline{Y}, K1)$

40/44


Exemple

CRU, PAYS \twoheadrightarrow REGION
REGION \twoheadrightarrow PAYS

R (CRU, PAYS, REGION), en 3NF

Décomposition BCNF :

R1(REGION, PAYS)
R2(CRU, REGION)



41/44

Décomposition en BCNF

Algorithme:

- (1) Pour R(A) et X t.q. $X^+ \neq X \neq A$
 - Décomposer en $R_1(X \cup \{A - X^+\})$ et $R_2(X^+)$
- (2) Répéter le premier pas pour R_1 et R_2

Comment tester si R(A) en BCNF?

- calcul de X^+ pour chaque $X \rightarrow Y$ dans F,
- test si $X^+ = A$ ou $X^+ = X$

Exemple: CSJDPQV, clé C, SD \rightarrow P, J \rightarrow S, JP \rightarrow C

Exemple sans SPD: ABC, AB \rightarrow C, C \rightarrow B


On ne peut pas décomposer sans perdre AB \rightarrow C

42/44

Exemple

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

$A \rightarrow B$
 $B \rightarrow C$



Si on choisit d'abord B^+ (ou AB^+) ?

43/44

Conclusion

□ Normalisation utile

- pour obtenir une représentation canonique des entités du monde réel
- pour améliorer la performance de la BD

□ Normalisation automatisable

- Algos 3NF
- outils du commerce (Power Designer, ER-Win, etc.)

44/44