


# *Théorie de la Normalisation*

# *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.

# Conception de schéma


Modèle conceptuel:



Modèle relationnel +  
DFs



Normalisation:  
Éliminer les anomalies



# *Théorie de la normalisation*

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

# *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.

# Décomposition

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



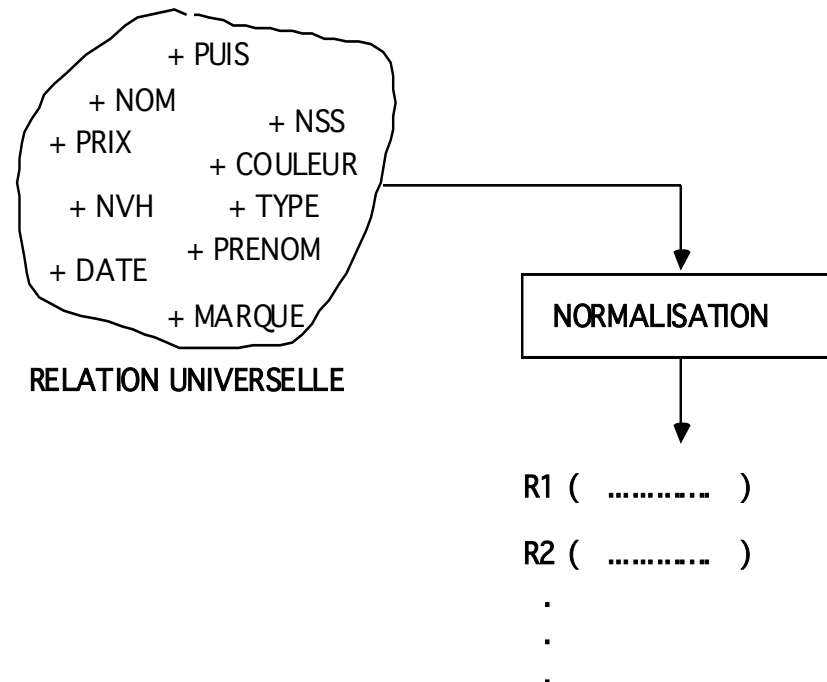
V_TYPE	MARQUE	TYPE	PUIS
	RENAULT	R21	7
	PEUGEOT	205	8

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

# 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 :



# 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.



# 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

# *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 ?

# Observation

Si ces deux DFs vérifiées:

nom  $\rightarrow$  couleur  
couleur, catégorie  $\rightarrow$  prix

Alors cette DF vérifiée aussi:

nom, catégorie  $\rightarrow$  prix

Explication?

# 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

$X \rightarrow Y$

$\Rightarrow X \rightarrow YZ$

$X \rightarrow Z$

### Pseudo-transitivité

$X \rightarrow Y$

$\Rightarrow XW \rightarrow Z$

$YW \rightarrow Z$

### Décomposition

$X \rightarrow Y$

$\Rightarrow X \rightarrow Z$

Z inclus dans Y

# $F^+$ 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.

# *Calcul de $F^+$*

- Avec les axiomes de Armstrong
  - Trop compliqué!

$X^+$ : 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:

$\text{nom}^+ = \{\text{nom}, \text{couleur}\}$

$\{\text{nom}, \text{catégorie}\}^+ = \{\text{nom}, \text{catégorie}, \text{couleur}, \text{département}, \text{prix}\}$

$\text{couleur}^+ = \{\text{couleur}\}$

# *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)
```

$\{\text{nom, catégorie}\}^+ = \{\text{nom, catégorie, couleur, département, prix}\}$   
 $\text{nom, catégorie} \rightarrow \text{couleur, département, prix}$



## *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  $X \cap Y = \emptyset$

# *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)

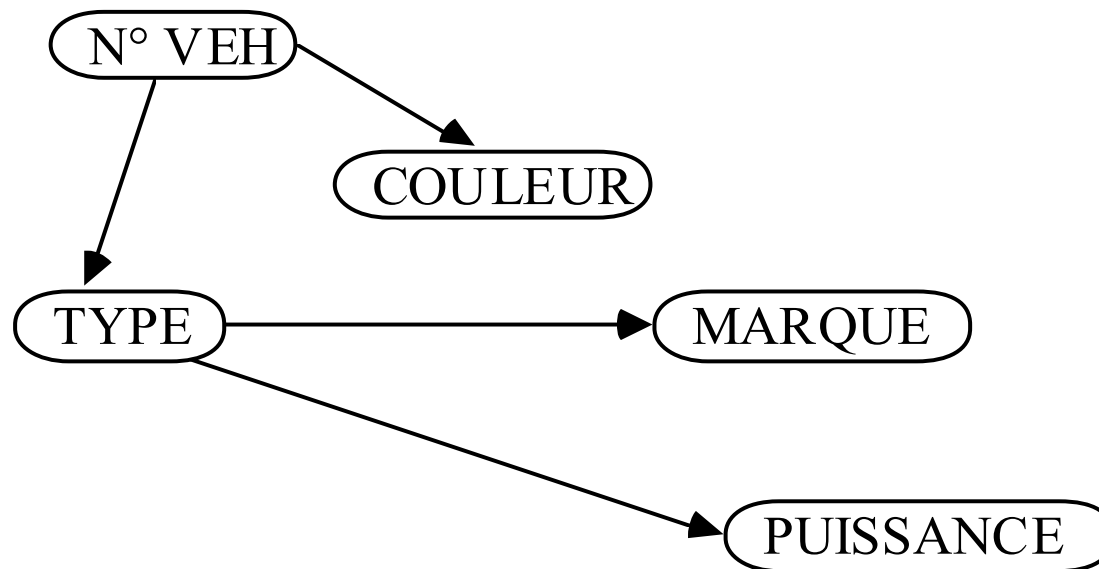
□ Une est choisie comme clé primaire

## □ Sur-clé :

□ Sur-clé :  $X$  est sur-clé ssi  $X \rightarrow R$  dans  $F^+$

# Graphe des DF

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




# *Autre Exemple*

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

CRU --> TYPE

TYPE, CLIENT --> REMISE



## *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.

# *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**

# 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  $R_2$ .

# Décomposition Sans Perte d'Information

**Preuve :**

On cherche a démontrer que  $\Pi_{R1} (r) \times \Pi_{R2} (r) = r$ .

❖  $r \subseteq \Pi_{R1} (r) \times \Pi_{R2} (r)$  est toujours vrai.

Soient r:

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

$\Pi_{R1} (r) :$

A	B
a1	b1
a2	b2
a3	b1

$\Pi_{R2} (r) :$

B	C
b1	c1
b2	c2
b1	c3

$\Pi_{R1} (r) \times \Pi_{R2} (r) :$

A	B	C
a1	b1	c1
<b>a1</b>	<b>b1</b>	<b>c3</b>
a2	b2	c2
<b>a3</b>	<b>b1</b>	<b>c1</b>
a3	b1	c3



# *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  $t \notin r$


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

# Exemple

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

# *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 projection 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.

# Example (1)

Exemple

1) R1 (NVH, TYPE, COULEUR) => F1 = { NVH -> TYPE, NVH -> COULEUR }

R2 (TYPE, MARQUE, PUIS) => F2 = { TYPE -> MARQUE, TYPE -> PUIS }

==> OK

2) R'1 (NVH, TYPE) => F'1 = { NVH -> TYPE }

R'2 (TYPE, PUIS, COULEUR) => F'2 = { TYPE -> PUIS }

R'3 (TYPE, MARQUE) => F'3 = { TYPE -> MARQUE }

==> ON A PERDU LA DF : NVH -> COULEUR

# Exemple (2)

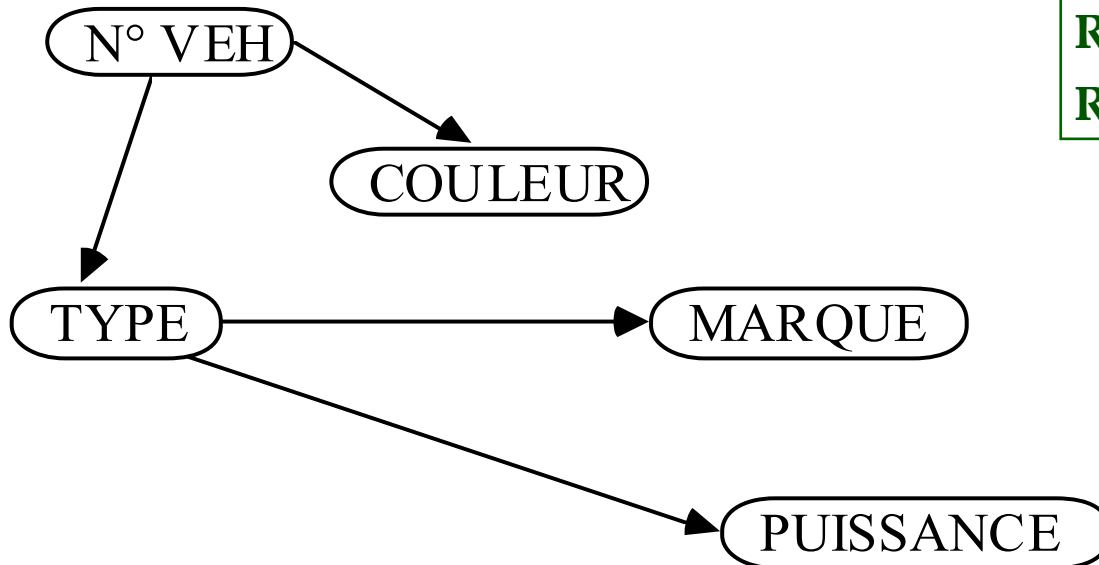
VOITURE (NVH, MARQUE, TYPE, PUIS, COULEUR)

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)



# *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.

# 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

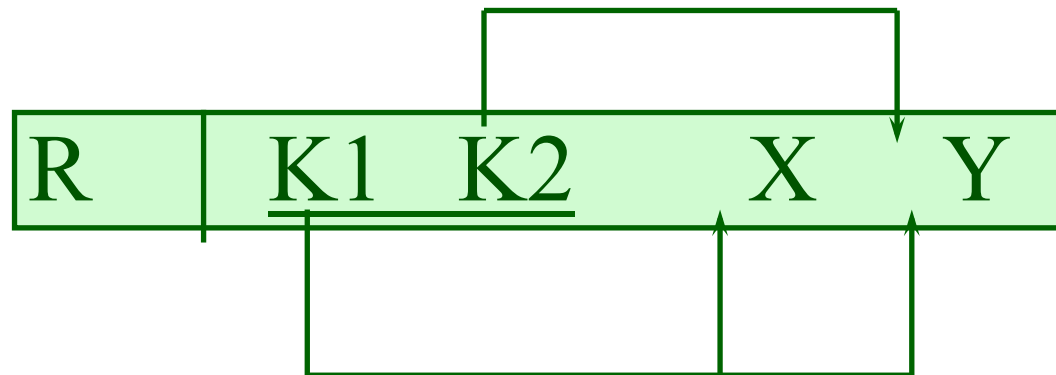
# 2NF

## 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

$R1(\underline{K1}, \underline{K2}, X)$  et  $R2(\underline{K2}, Y)$



## *Exemple 2NF*

### ❑ Exemple 1 :

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

### ❑ Exemple 2 :

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


# 3NF

## □ Définition

□ une relation est en 3e forme normale ssi :

- elle est en 1ère forme
- tout attribut **n'appartenant pas a 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

$R1(\underline{K}, X, Y)$  et  $R2(X, Z)$

# *Exemple 3ème Forme*

## ❑ Exemple

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

- ❑ Type --> marque

- ❑ Type --> puissance

Pas en 3eme forme !

## ❑ Caractéristiques de la 3NF :


- ❑ redondance limitée

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

# Exemples de décomposition

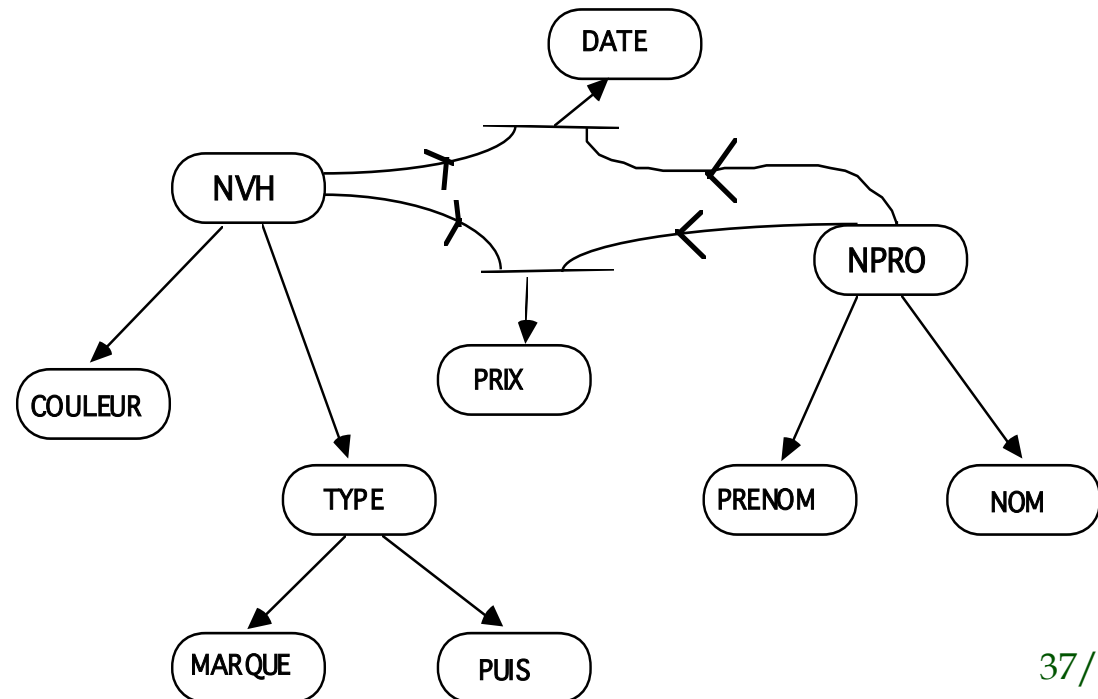
- ❑ Voiture (nvh, marque, type, puissance, couleur)
  - véhicule (nvh, type, couleur)
  - Modèle (type, marque, puissance)

- ❑ Réduction (cru, type, client, remise)
  - Remise (Type,client,remise)
  - Type (cru,type)
  - Commande(Cru, Client)



# 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 :  $A_i \rightarrow A_j$
3. Editer la relation (X, A1, ... , An) qui est en 3FN
4. Supprimer les DFs ( $X \rightarrow A_1, \dots, X \rightarrow A_n$ ) 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

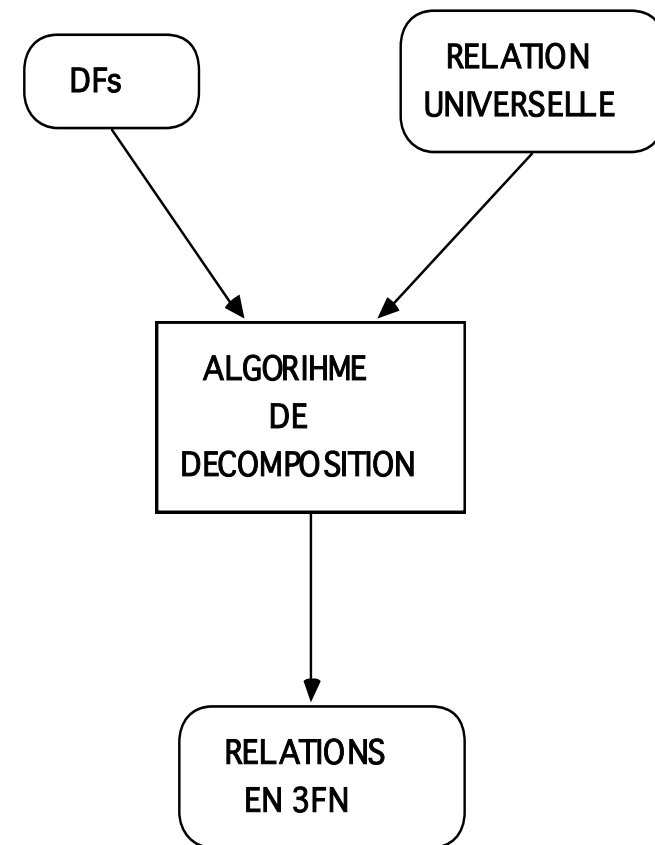


## *Comment tester si R en 3NF?*

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

# *Automatisation de la décomposition*

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



# 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

$R1(\underline{K2}, \underline{Y}, X)$  et  $R2(\underline{Y}, K1)$



# Exemple

CRU, PAYS  $\twoheadrightarrow$  REGION

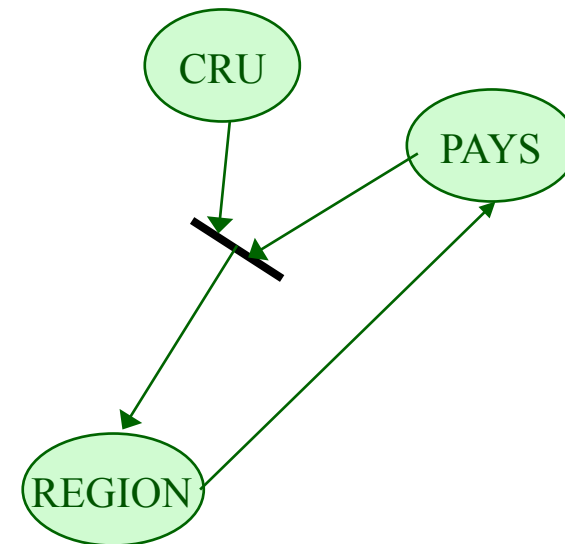
REGION  $\twoheadrightarrow$  PAYS

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

**Décomposition BCNF :**

**R1(REGION, PAYS)**

**R2(CRU, REGION)**



# 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,  $AB \rightarrow C$ ,  $C \rightarrow B$

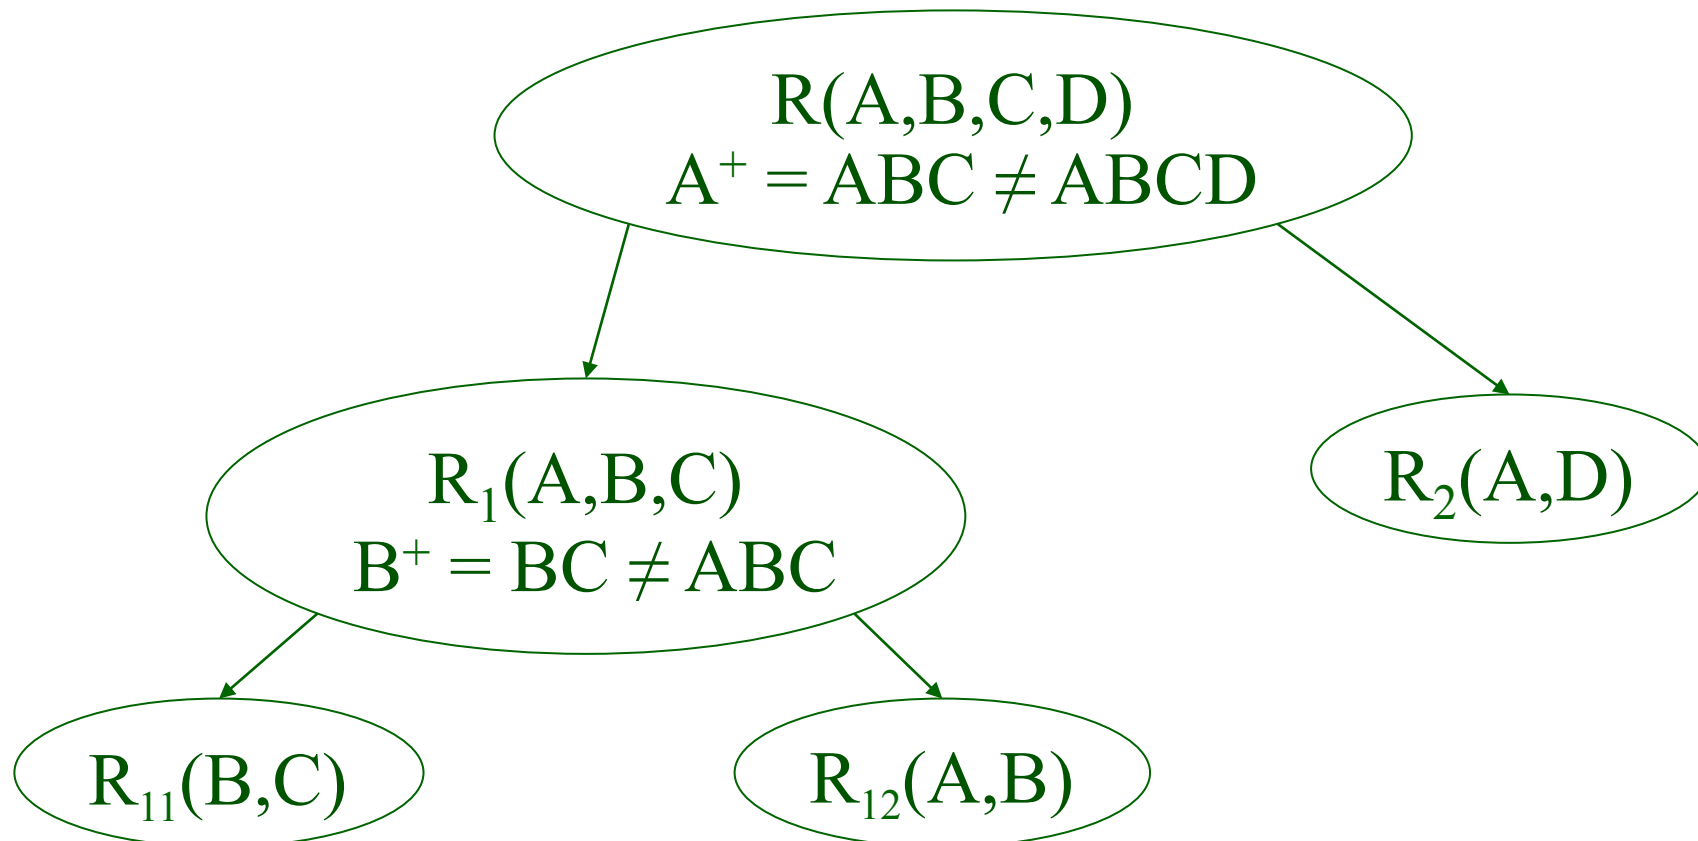
On ne peut pas décomposer sans perdre  $AB \rightarrow C$

# Exemple

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

$A \rightarrow B$

$B \rightarrow C$



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

# *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.)