

# Données et modélisation

## 1. Données numériques

Les données numériques sont une des composantes essentielles des programmes informatiques.



- Il s'agit par définition des *informations qui doivent être conservées entre deux exécutions*.
- Avec l'augmentation des capacités de stockage et leur mise en réseau, les quantités de données conservées ont considérablement augmenté au cours des dernières décennies.

La conservation des données repose principalement sur la **mémoire secondaire**,



- définissant la manière dont les données sont physiquement stockées sur le support,
- autrement dit la méthode de **rangement** de la série de mesures :
  - fichiers,
  - répertoires,
  - index,
  - etc...

### Persistance des données



- Contrairement à la mémoire primaire (comme la RAM) rapide et volatile (utilisée pour exécuter les programmes en cours), la mémoire secondaire conserve les informations même en l'absence d'alimentation électrique.
- Elle est généralement plus lente que la mémoire primaire, mais offre une capacité de stockage beaucoup plus importante.
- Les exemples courants de mémoire secondaire incluent les disques durs (HDD), les disques SSD, les clés USB, et les supports optiques comme les CD ou DVD.

### Fichiers et répertoires

La mémoire secondaire n'est pas directement accessible (les programmes n'ont pas la possibilité d'aller écrire directement sur le disque). Le système d'exploitation assure ainsi l'indépendance du programme par rapport à l'emplacement des données, au travers d'instructions d'entrée/sortie spécialisées.

Pour que les programmes puissent écrire sur le disque, on introduit des objets intermédiaires : les fichiers. Un fichier est caractérisé par (nom, emplacement (volume, arborescence), droit d'accès,

taille,...). Il s'agit d'une entité logique. Tout programme utilisant un fichier passe par le système d'exploitation qui, à partir des informations, détermine la localisation des données sur le support.

### A retenir :



- Un fichier est une référence vers un ou plusieurs blocs de données, enregistrés sur un support physique.
- Un fichier est caractérisé par son descripteur, constitué de son nom, son chemin d'accès, ses droits d'accès (lecture/écriture/exécution) selon les utilisateurs, sa position sur le support, sa taille, etc...

- La gestion des fichiers est une des fonctions essentielles des systèmes d'exploitation :
  - possibilité de traiter et conserver des quantités importantes de données
  - possibilité de partager des données entre plusieurs programmes.

### Opérations de base :



- *Ouverture* : initialisation d'un **flux** en lecture ou en écriture
- *Lecture* : consultation des lignes l'une après l'autre (à partir de la première ligne), dans l'ordre où elles ont été écrites sur le support
- *Ecriture* : ajout de nouvelles données à la suite ou en remplacement des données existantes

### Organisation hiérarchique :

- Lorsque le nombre de fichiers est élevé, les descripteurs de fichiers sont classés dans plusieurs répertoires, organisés sous une forme arborescente.
- Le répertoire de plus bas niveau hiérarchique est appelé racine → chemin d'accès (path)



## Consultation des données : lecture d'un fichier (Read)

### FileReader

La consultation des données nécessite d'ouvrir une "communication" entre le programme et les fichiers. Ce canal de communication permet de recevoir un flux de données.



Pour établir la communication, il faut connaître : le "chemin d'accès" aux données (disque dur local) l'"adresse" des données (lorsqu'il s'agit de données stockées sur un serveur distant)

L'opération d'ouverture de fichier initialise un descripteur de fichier, qui sert à désigner (dans le programme) le fichier sur lequel on travaille, et d'accéder au contenu du flux.

```
FileReader f = new FileReader("/chemin/vers/mon/fichier.txt");
```

### BufferedReader



Les opérateurs de lecture et d'écriture ne travaillent pas directement sur les données du fichier. Les données du fichier sont dans une mémoire "tampon". Lors des opérations de lecture, la mémoire tampon est mise à jour au fur et à mesure qu'on



avance dans la lecture du fichier par des opérations de lecture sur le disque.

```
BufferedReader br = new BufferedReader(f);
```



**Gestion des Exceptions** Il est important de vérifier que cette opération d'ouverture s'effectue correctement avant de poursuivre le programme (nombreuses possibilités d'erreur : fichier effacé, erreur de nom, pas de droits de lecture,...).

On utilise la gestion des exceptions permettant de prévoir une action de secours lorsqu'une opération "risquée" échoue.

## Lecture séquentielle

Lorsque l'opération d'ouverture est réalisée avec succès, le flux de données devient accessible en lecture (les premières lignes du fichier sont chargées en mémoire et une tête de lecture se positionne sur le premier caractère de la première ligne). Il ne reste plus qu'à lire les données.

La consultation des données s'effectue séquentiellement à l'aide de l'opérateur de lecture `readLine`. Chaque appel à cet opérateur charge les nouvelles données et déplace la tête de lecture vers les données suivantes. Cette opération peut être effectuée plusieurs fois jusqu'à atteindre la fin de fichier.

```
try (BufferedReader br = new BufferedReader(new  
FileReader("/chemin/vers/mon/fichier.txt"))) {  
    String ligne;  
    while ((ligne = br.readLine()) != null) {  
        System.out.println(ligne);  
    }  
} catch (IOException e) {  
    e.printStackTrace();  
}
```

### Voir aussi :

- [Gestion des fichiers sous Unix](#)

## 2. Données structurées



Une donnée structurée est une information :

- organisée selon un format ou un schéma prédéfini
- ce qui facilite son stockage, sa manipulation et son analyse.

Tout commence par une fiche à remplir...



Prénom  ✓

Nom  ✗ **Votre nom de famille est requis**

Nom d'utilisateur

Mot de passe

Confirmez le mot de passe

Adresse e-mail

Quel format est le mieux ?  14/02/07  02/14/07

J'ai lu et j'accepte les [conditions d'utilisation](#).

Un formulaire se présente sous la forme d'un ensemble de rubriques à remplir.

- Le **modèle de fiche** définit le format des données à enregistrer:
  - liste des rubriques du formulaire,
  - domaine de valeurs attendues dans chaque rubrique.
- A toute fiche remplie correspond un **jeu de valeurs** (ou mesure) :
  - liste de valeurs correspondant au contenu d'une fiche particulière.

On peut donc générer à partir d'un modèle de formulaire un grand nombre de données **obéissant au même format\***

**Exemple:** un schéma de données décrivant des informations sur des clients avec des colonnes pour le nom, l'adresse, et le numéro de téléphone

Ces données sont généralement stockées dans des formats tabulaires (comme les tableaux ou fichiers CSV) où chaque donnée est placée dans des champs ou colonnes clairement définis.

Un tableau de données est une liste (finie et ordonnée) de tuples, chaque tuple obéissant à un même schéma \$R\$.

Tableau de données

Nom	Prénom	Adresse	Âge
Dubois	Martine	29, rue du Verger, Orléans	22
Gilbert	Jonas	8, rue des Fleurs, Blois	23
Dalban	Pierre	13, av. du Général, Privas	22
...	...	...	...
Manoukian	Marianne	55, place des Bleuets, Aubagne	24

schéma

tuple

Ce type de données est facilement lisible par les machines et exploitable grâce à des langages de requête.

### Formats d'échange

Les principaux formats d'échange de données sont :

- csv
- json
- xml

#### Le format csv - "Comma Separated Values"

Chaque enregistrement est codé sur une ligne, chaque valeur étant séparé par un caractère séparateur (virgule, point-virgule, tabulation,...).

Exemple :



```
Dubois,Martine,"28, rue des Lilas, 45000 Orléans",45
```

Remarques :

- les données sont des chaînes de caractères
- les guillemets sont nécessaires lorsque la valeur contient le caractère séparateur (ici la virgule)
- les noms des attributs sont éventuellement indiqué sur une ligne séparée

Exemples :

- [codes postaux](#)

## Le format json - JavaScript Object Notation

Exemple :



```
{"nom" : "Dubois", "prénom" : "Martine", "adresse" : "28, rue des Lilas, 45000, Orléans", "âge" : 45}
```

Remarques :

- reprend la syntaxe du dictionnaire Python
- données numériques ou chaînes de caractères

\* [codes postaux](#)

Pour les données organisées de manière hiérarchique. Des balises servent à séparer les différents attributs.

## Formats xml, xhtml, json, ...

Ex :

```
<nom> Dubois </nom>
<prénom> Martine </prénom>
<adresse>
  <num> 28 </num>
  <voie> rue des Lilas </voie>
  <code postal> 45000 </code postal>
  <ville> Orléans </ville>
</adresse>
<âge> 45 </âge>
```



remarque : le format json permet également de définir des hiérarchies

```
{
  "nom" : "Dubois",
  "prénom" : "Martine",
  "adresse" :
  {
    "numero" : 28,
    "voie" : "rue des Lilas",
    "code_postal" : 45000,
    "ville" : "Orléans"
  },
  "âge" : 45
}
```

Exemples :

- [Clients](#)
- [Cours de l'Euro](#)

## Jeu de valeurs

Un jeu de valeurs sert à décrire :



- une personne réelle : assuré, client, étudiant, auteur, plaignant, contribuable,...
- une personne morale : fournisseur, prestataire, direction, section, promotion,...
- un objet physique : article, véhicule, composant, ingrédient, pièce,...
- un objet contractuel ou administratif : fiche de paye, contrat, procès verbal, billet, dossier...
- un lieu : salle, local, manufacture, entrepôt, ligne de production,...
- un événement : transaction, jugement, achat, vente, acte administratif, appel téléphonique,...
- etc...

- D'un point de vue informatique, un jeu de valeurs recueilli est appelé un *enregistrement*
  - correspondant à l'encodage des données recueillies sur un support numérique

## Tuple

Le **Tuple** est la structure de données de base servant pour le recueil, le transport et le stockage des données.



- Un **Tuple** est une liste, **finie**, **ordonnée** et **de taille fixe** contenant une suite de valeurs.
- Chaque valeur peut obéir à un format différent
- On note  $m$  la taille du tuple (nombre de valeurs)

$t = (a_1, \dots, a_m)$  **Exemple :**

`("Dubois", "Martine", 22, "29/10/1994", "Orléans")`

## Indexation

Pour une gestion efficace des données, il est nécessaire de pouvoir identifier chaque jeu de valeurs (tuple) de façon unique.

L'indexation des données repose sur un principe simple d'étiquetage consistant à attribuer une étiquette différente à chaque enregistrement.

1. Cette étiquette peut être une suite de caractères arbitraires, un entier, ou un descripteur explicite. On parle en général de **clé** ou d'**identifiant** pour désigner cette étiquette.
2. Il existe un ordre total dans le domaine de valeurs des clés, permettant d'effectuer des opérations de tri sur les données à partir de la valeur de leur clé.

## Définitions et propriétés

- L'**indexation** des données consiste à attribuer à chaque jeu de valeurs distinct un **identifiant** unique.
- On parle également de *clé* de l'enregistrement:

On peut représenter l'opération d'indexation sous la forme d'une fonction. Si  $d$  est le jeu de valeurs,  $k(d)$  désigne l'identifiant de ce jeu de valeurs.

## Unicité/spécificité

L'indexation suppose l'existence d'une bijection entre l'ensemble des données et l'ensemble des clés, permettant d'assurer l'unité et la spécificité de la clé



- soient  $d_1$  et  $d_2$  deux enregistrements,
- Unicité :
  - si  $d_1 = d_2$ , alors  $k(d_1) = k(d_2)$ .
- Spécificité:
  - si  $k(d_1) = k(d_2)$ , alors  $d_1 = d_2$ .

## Compacité

L'identifiant doit en pratique tenir sur un nombre d'octets le plus petit possible pour que la liste  $L$  puisse être manipulée en mémoire centrale. Autrement dit, il faut que :

- $|k| \ll |d|$

pour que :

- $|L| \ll |D|$



Un identifiant entier, codé sur 4 octets, permet d'indexer jusqu'à  $2^{4 \times 8} \approx 4 \times 10^9$  données différentes.

## Efficacité

L'existence d'un identifiant unique pour chaque jeu de valeurs  $d$  permet la mise en œuvre d'une

recherche par identifiant (ou recherche par clé).

La recherche par identifiant repose sur une fonction d'adressage  $I$  (dite "Index") qui à tout identifiant  $k$  associe sa position (entrée)  $i$  dans un tableau de données:  $I : k \rightarrow i$ . Ainsi si  $k$  est l'identifiant servant à la recherche, l'extraction des informations se fait en 2 étapes:

- $i = I(k)$  (lecture de l'index des données)
- $d = D[i]$  (lecture des données elles mêmes)

La fonction d'indexation repose en pratique sur

- une liste ordonnée de clés (ou toute autre structure ordonnée)



$L = (k_1, k_2, \dots, k_N)$  telle que  $k_1 < k_2 < \dots < k_N$ , de telle sorte que la recherche dans cette liste s'effectue en  $O(\log N)$  (recherche dichotomique).

- une table de correspondances qui associe à chaque  $k$  l'adresse  $i$  correspondante.

## Utilisation

### Définir un ordre sur les données

La présence d'un identifiant permet de définir un ordre total sur les données :

- ordre sur les entiers (identifiant entier)
- ordre alphabétique (identifiant texte)
- ordre *ASCII*bétique (chaîne de caractères quelconque)

### Lier les données

Dans le cas des bases de données, l'identifiant constitue une *référence* vers les jeux de valeurs des tableaux de données. Une référence permet de *lier* les données d'une table aux données d'une autre table.

Exemple :

- [Artistes](#)
- [Albums](#)
- [Pistes](#)
- Pour chaque album de la table des albums, l'identifiant d'artiste (ici un numéro) permet de lier l'album avec l'artiste (ou groupe) correspondant.
- Pour chaque piste de la table des pistes, l'identifiant d'album permet de lier la piste à l'album correspondant (et donc à l'artiste correspondant par transitivité)



**Exercice :** donner le nom du groupe qui interprète la piste '*Paradise City*'.

## Structure d'ensemble

L'index définit l'*appartenance* d'une donnée à un ensemble.

Soit  $\mathcal{E}$  un *ensemble* de données indexées :  $\mathcal{E} = \{d_1, d_2, \dots, d_K\}$  On a l'équivalence :  $d \in \mathcal{E} \Leftrightarrow k(d) \in I$

Ainsi, il ne peut y avoir de doublon car  $\forall d$  :

- $k(d)$  est unique
- $i = I(k(d))$  est unique ssi  $d \in \mathcal{E}$  et indéfini sinon.

## 4. Modèle Relationnel

On introduit dans ce chapitre le **modèle relationnel** qui sert de fondation à la conception de bases de données.

Les différents modèles utiles en représentation des connaissances reposent sur des notions de base de la théorie des ensembles :

- Ensemble finis
- Éléments partiellement (ou totalement) discernables

## 2. Schéma et relation

2 approches en modélisation :

- approche ensembliste (plus général)
- modèle relationnel (plus pratique)



Le **Modèle relationnel** sert à représenter logiquement les **tableaux de données**.

### Tableau de données

Un tableau de données est une liste (finie et ordonnée) de tuples, chaque tuple obéissant à un même schéma  $SR$ .





Tableau de données

Nom	Prénom	Adresse	Âge
Dubois	Martine	29, rue du Verger, Orléans	22
Gilbert	Jonas	8, rue des Fleurs, Blois	23
Dalban	Pierre	13, av. du Général, Privas	22
...	...	...	...
Manoukian	Marianne	55, place des Bleuets, Aubagne	24

schéma

tuple


Rappel:

- Un enregistrement est un jeu de valeurs organisé sous forme de **tuple**
- A un tuple on associe en général un **schéma de données**.


<u>SCHEMA :</u>	<b>Nom</b>	<b>Prénom</b>	<b>Adresse</b>	<b>Âge</b>
<u>DONNEES :</u>	Dubois	Martine	29, rue du Verger, Orléans	22

- Définir un **schéma** consiste à définir :
  - une liste d'attributs (labels) associées à chacune des valeurs du tuples.
- A chaque **attribut** correspond :
  - un *intitulé*
  - un *domaine* de valeurs (type/format des données)
- Soit  $R(A_1, \dots, A_m)$  un schéma.
- On note  $\text{dom}(A_i)$  le domaine associé à l'attribut  $A_i$ .
- On dit d'un tuple  $t$  qu'il *obéit au schéma*  $R$  si les valeurs qu'il contient correspondent aux domaines des attributs du schéma.

**Définition**

 Soit  $R = (A_1, \dots, A_m)$  un schéma de données

Une **relation**  $r$  obéissant au schéma  $R$  est un *sous-ensemble du produit cartésien*  $\text{dom}(A_1) \times \dots \times \text{dom}(A_m)$

 **Corollaire** : une relation est un **ensemble** de tuples :  $r = \{t_1, \dots, t_n\} = \{(a_{11}, \dots, a_{1m}), \dots, (a_{n1}, \dots, a_{nm})\}$



- avec :
  - $\forall (i,j), a_{ij} \in \text{dom}(A_j),$
  - $\forall i, t_i \in \text{dom}(A_1) \times \dots \times \text{dom}(A_m)$
  - $n$  : nombre de tuples
  - $m$  : nombre d'attributs par tuple


**Remarque :**



- Le **schéma**  $R$  représente le niveau abstrait (modélisation)
- La **relation**  $r$  représente un cas concret de réalisation (à un schéma  $R$  peuvent correspondre une infinité de réalisations possibles :  $r, r', r'',$  etc.)

**Diverses représentations :**

Entité/association :



UML :




Schéma relationnel :

**Client**(nom, prénom, adresse, âge)

### Exemples de schémas relationnels :



**Étudiant**(nom, prénom, adresse, INE)

**Ouvrage**(titre, auteur, éditeur, prix, date\_édition)

**Véhicule**(immatriculation, marque, modèle, couleur)

## 3. Dépendances fonctionnelles

- Au sein d'un schéma  $R$ ,
  - Il peut exister un ensemble de contraintes, noté  $F$ ,
    - portant sur les attributs (plus précisément sur les valeurs prises par les attributs).
    - L'ensemble  $F$  est indépendant de  $R$ .
  - On parle de **contraintes d'intégrité**.
    - Ces contraintes s'expriment sous la forme de **dépendances fonctionnelles**.

### Rappels d'algèbre de base:



- **Relation binaire** : une relation binaire  $r$  portant sur deux domaines  $\text{dom}(A)$  et  $\text{dom}(B)$ :
  - est un sous-ensemble du produit cartésien  $\text{dom}(A) \times \text{dom}(B)$ .
  - si  $(a,b) \in r$ , on note parfois  $a r b$  ce qui signifie "a est en relation avec b".
- **Fonction** : une fonction  $f : \text{dom}(A) \rightarrow \text{dom}(B)$  est une relation binaire sur  $\text{dom}(A) \times \text{dom}(B)$  telle que
  - pour tout  $a \in \text{dom}(A)$ ,
  - il existe un unique  $b$  tel que  $(a,b) \in f$ .
  - On note  $b=f(a)$ ,
    - ce qui signifie qu'au sein de la relation  $f$ ,  $b$  est déterminé de façon unique par le choix de  $a$  (autrement dit : "b dépend de a")

### Dépendance fonctionnelle



- Soit  $r$  une relation définie selon  $R(A_1, \dots, A_m)$
- Soient  $X$  et  $Y$  deux sous-ensembles de  $R$
- On dit que la relation  $r$  définit une *dépendance fonctionnelle* de  $X$  vers  $Y$ ,
  - notée  $X \stackrel{r}{\rightarrow} Y$
  - si les valeurs de  $r$  permettent de définir une fonction de  $\text{dom}(X)$  vers  $\text{dom}(Y)$ .



### Exemple 1 :

Soit la relation \$r\$:

A	B	C
1	a	e
2	b	f
2	c	f
3	d	k
4	d	k



- On a les dépendances suivantes :
  - $A \rightarrow C$
  - $B \rightarrow C$
  - mais pas :  $A \rightarrow B$ ,  $B \rightarrow A$ , ni  $C \rightarrow A$
- On a aussi :
  - $A, B \rightarrow C$
  - mais pas :  $B, C \rightarrow A$ , ni  $A, C \rightarrow B$ , etc.

### Exemple 2 :

- Soit le schéma :
  - **Commande** (num\_client, quantité, prix, date, num\_article)
- et l'ensemble de contraintes



```


$$\begin{array}{l} F \equiv \{ \text{num\_client, date} \rightarrow \text{num\_article,} \\ \text{quantité, prix} \} \ \& \ \& \ \text{num\_article, quantité} \rightarrow \text{prix} \ \& \ \end{array}$$


```

- La première contrainte indique qu'il ne peut y avoir deux factures émises pour un même client à une date donnée.
- La seconde contrainte indique que le prix payé dépend de l'article et de la quantité commandée.

### Exemple 3 :

- Soit le schéma :
  - **Ouvrage** (titre, auteur, éditeur, prix, date\_édition)
- et la contrainte :
  - {titre, auteur, éditeur  $\rightarrow$  prix, date\_édition}



La contrainte signifie :

- "pour une oeuvre chez un certain éditeur, une seule édition est possible (pas de réédition à une date ultérieure)"
- "politique du prix unique"



**Exercice :** Soit le schéma :

- **Réservation**(code\_appareil, date, heure, salle)



Exprimer la dépendance fonctionnelle :

- « *Un appareil ne peut pas être utilisé dans deux locaux différents au même moment* »

- Il importe donc de bien réfléchir, au moment de l'étape de conception,
  - du réalisme et du caractère limitant de certaines dépendances fonctionnelles,
  - et du caractère éventuellement limitant du choix des attributs.
- Ainsi, le schéma décrivant les commandes (exemple 2)
  - ne permet pas de commander des articles de nature différente au sein d'une même commande
  - (un client, pour commander deux râtaux et une truelle, doit donc effectuer deux commandes, qui plus est à des dates différentes!).

### Exercice

Soit le schéma relationnel suivant :



**Billet**(num\_train, type\_train, num\_voiture, num\_place, date, id\_passager, nom\_passager, prénom\_passager, date\_naissance, gare\_départ , horaire\_départ, gare\_arrivée, horaire\_arrivée, classe, tarif)

Définir des dépendances fonctionnelles sur cet ensemble d'attributs

## 4. Clé d'une relation

### 4.1 Définitions

- Soit un schéma  $R(A_1, \dots, A_m)$ .

#### Clé

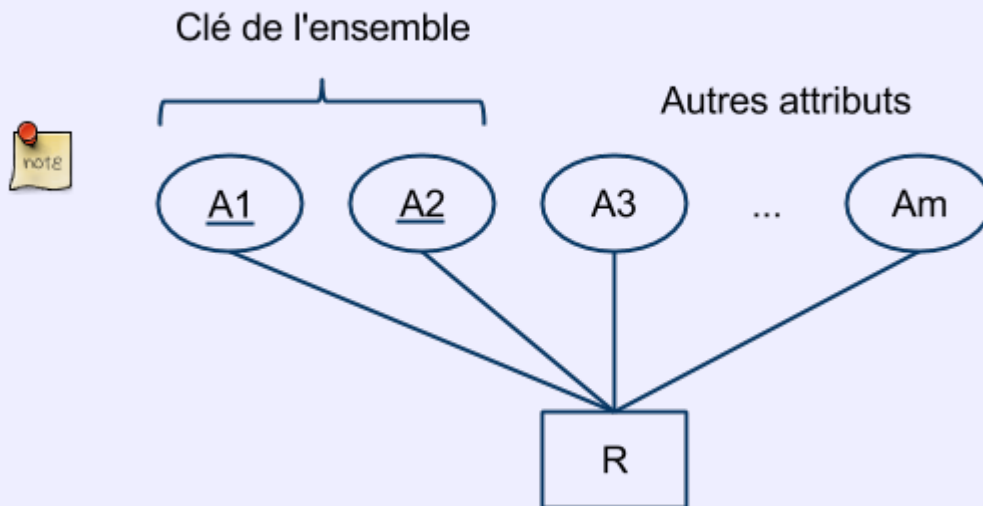


- Une **clé**  $K$  :
  - est un ensemble **minimal** d'attributs inclus dans  $R$ ,
  - tel que toute relation  $r$  de schéma  $R$  définit une dépendance fonctionnelle de  $\text{dom}(K)$  dans  $\text{dom}(R)$ ,
- cette dépendance est notée  $K \rightarrow R$ .



- **Remarques :**
  - Si un schéma  $R$  possède une clé  $K$ , alors tous les éléments d'une relation  $r$  de schéma  $R$  sont discernables : la valeur de la clé permet

- d'identifier de façon unique chaque élément de l'ensemble.
- Au sein d'un schéma, il est souvent possible de définir plusieurs clés à partir des attributs. Le concepteur du modèle choisit une clé parmi les clés possibles. Cette clé est appelée **clé primaire**.
- Graphiquement, les attributs constituant la clé sont soulignés:



**Exemple 1 :**





**Exemple 2 :**





- Pour certains schémas,
  - il est courant de définir comme clé un entier **identifiant de façon unique** chaque élément de l'ensemble (appelé identifiant ou "Id").
  - La clé est alors constituée de cet attribut unique.



Représentation UML :

## 4.2 Axiomes d'Amstrong

Soit  $K$  une clé candidate. On démontre que  $K \rightarrow R$  à l'aide des *axiomes d'Amstrong* à partir d'un ensemble de DF connues:

### Axiomes d'Amstrong



1. **Réflexivité** :  $Y \subseteq X \rightarrow X \rightarrow Y$
2. **Augmentation** :  $X \rightarrow Y \rightarrow X, Z \rightarrow Y, Z$
3. **Transitivité** :  $X \rightarrow Y$  et  $Y \rightarrow Z \rightarrow X \rightarrow Z$
4. **Pseudo-transitivité** :  $X \rightarrow Y$  et  $Y, W \rightarrow Z \rightarrow X, W \rightarrow Z$
5. **Union** :  $X \rightarrow Y$  et  $X \rightarrow Z \rightarrow X \rightarrow Y, Z$
6. **Décomposition** :  $X \rightarrow Y, Z \rightarrow X \rightarrow Y$  et  $X \rightarrow Z$

### Exercice

Soit le schéma relationnel suivant :



**Billet**(num\_train, type\_train, num\_voiture, num\_place, date, id\_passager, nom\_passager, prénom\_passager, date\_naissance, gare\_départ, horaire\_départ, gare\_arrivée, horaire\_arrivée, classe, tarif)

Montrer que l'ensemble {num\_train, num\_voiture, num\_place, date, gare\_départ} est une clé primaire du schéma?

## 4. Normalisation d'un schéma

### Tables mal construites

#### Exemple : fournisseurs de composants électroniques:

$\text{table}\{\text{Fournisseur}\}(\underline{\text{nom}_f, \text{composant}}, \text{adresse}_f, \text{prix})$



#### • Problèmes :

- **Redondance** : l'adresse des fournisseurs est répétée plusieurs fois
- **Inconsistance** : mauvaise mise à jour  $\Rightarrow$  adresses différentes pour un même fournisseur.
- **Problème Insertion** : on ne peut pas insérer dans la table un fournisseur qui ne fournit rien
- **Problème suppression** : si un fournisseur ne fournit plus rien, on perd son adresse

#### • Solution?

- Couper la table en 2?



$\\$\\$\\text{bf}{Fournisseurs} (\\text{nom}_f, adresse_f)\\$\\$$   
 $\\$\\$\\text{bf}{Catalogue}(\\text{composant, prix})\\$\\$$

-> Impossible de retrouver les prix pratiqués par les différents fournisseurs.



- Nouveau Schéma :



$\\$\\$\\text{bf}{Fournisseurs} (\\text{nom}_f, adresse_f)\\$\\$$   
 $\\$\\$\\text{bf}{Catalogue}(\\text{nom}_f, composant, prix)\\$\\$$

-> Il est possible de reconstruire la table initiale en effectuant une jointure entre ces 2 tables sur l'attribut  $nom_f$ .

**Exercice** : Les tables suivantes sont-elles bien ou mal construites?



- **Enseignement** ( $id\_enseignant, nom\_enseignant, matiere, id\_élève, nom\_élève$ )
- **Arrêt** ( $num\_train, horaire, nom\_gare, ville$ )
- **Facture** ( $id\_client, date, article, montant$ )

## 5. Formes Normales

### Les Formes normales

- Restreignent les dépendances admises dans un schéma relationnel
- Permettent d'éviter la duplication de l'information au sein des relations
- Définissent une méthode
  - de **décomposition** d'un schéma relationnel redondant
  - en plusieurs schémas *liés entre eux*:

#### 5.1 2ème forme normale (2FN)

##### Dépendance fonctionnelle élémentaire (DFE)



- Soit  $R$  un schéma relationnel
- Soit  $X$  un ensemble d'attributs  $\subseteq R$
- Soit  $A$  un attribut de  $R$
- Il existe une DFE entre  $X$  et  $A$  ssi :
  - $X \rightarrow A$



- Il n'existe aucun sous-ensemble  $Y \subseteq X$  tel que  $Y \rightarrow A$

## 2ème forme normale (2FN)



- Un schéma  $R$  est en 2FN :
  - ssi la clé primaire de  $R$  est en DFE avec tous les autres attributs.
  - Donc : il n'y a pas d'attributs qui ne dépendent que d'une partie de la clé.



**Exemple :**  $\text{Fournisseur}(\underline{\text{nom}_f}, \text{composant}, \text{adresse}_f, \text{prix})$   
 $\text{nom}_f \rightarrow \text{adresse}_f$   
 $\text{nom}_f, \text{composant} \rightarrow \text{prix} \Rightarrow$  Pas 2FN!!

## 5.2 Normalisation 2FN

- Lorsqu'un schéma relationnel n'est pas en deuxième forme normale, il doit être normalisé:

### Normalisation 2FN :

- Pour obtenir un schéma 2FN:
  - on "*découpe*" la table selon les DFE trouvées entre les attributs de la clé et ceux qui ne sont pas dans la clé.
- La normalisation consiste:
  - à créer une nouvelle table pour chaque DFE ainsi trouvée.
- Soit :

$\mathbf{R}$   
 $(\underline{A_1, \dots, A_i}, \dots, A_n, B_1, \dots, B_j, \dots, B_m)$

- avec :



$\color{red}{A_i} \stackrel{\text{DFE}}{\rightarrow} \color{red}{B_j}$   
 $(\underline{A_1, \dots, A_i}, \dots, A_n, B_1, \dots, B_{j-1}, B_{j+1}, \dots, B_m)$

- Alors le schéma de table doit être modifié comme suit :

$\mathbf{R_1}$   
 $(\underline{A_1, \dots, A_i}, \dots, A_n, B_1, \dots, B_{j-1}, B_{j+1}, \dots, B_m)$   
 $\mathbf{R_2}(\underline{\color{red}{A_i}}, \color{red}{B_j})$

### Attention



Même si aucun attribut ne dépend plus de la clé primaire initiale, il est important de la conserver dans une table spécifique (elle sert à "lier" les valeurs dispersées dans les différentes tables).

### Exemple

- Avant:

$$\begin{matrix} \text{\textbf{Fournisseur}}(\underline{\text{nom\_f,composant}}, \text{adresse\_f,} \\ \text{prix}) \\ \text{nom\_f} \rightarrow \text{adresse\_f} \\ \text{prix} \end{matrix}$$

- Après:

$$\begin{matrix} \text{\textbf{Catalogue}}(\underline{\text{nom\_f,composant}}, \text{prix}) \\ \text{\textbf{Fournisseur}}(\underline{\text{nom\_f}}, \text{adresse\_f}) \end{matrix}$$



**Remarque :** le schéma est maintenant constitué de deux tables.



- Les tables ont un attribut commun : *nom\_f* (clé primaire de la table Fournisseur).
- La clé primaire de la table des Fournisseurs est dupliquée dans la table des prix (appelée ici **Catalogue**).
- On dit que *nom\_f* est une **clé étrangère** de la table des prix (l'attribut fait référence à la clé primaire d'une autre table, en l'occurrence la table des fournisseurs - voir 3.1.1).

## 5.3 3ème forme normale (3FN)

### Dépendance Fonctionnelle Directe (DFD) :



La dépendance fonctionnelle entre 2 attributs  $A_i$  et  $A_j$  est *directe* s'il n'existe pas de  $A_k$  tel que :  $A_i \rightarrow A_k \rightarrow A_j$

### 3ème Forme Normale (3FN)



Un schéma est 3FN :

- S'il est 2FN
- Si tous les attributs sont en DFD avec la clé.

### Exemple :



$$\begin{matrix} \text{\textbf{Commande}}(\underline{\text{num\_commande}}, \text{nom\_f, adresse\_f,} \\ \text{composant, quantité}) \\ \text{num\_commande} \rightarrow \text{nom\_f,} \\ \text{composant, quantité} \\ \text{nom\_f} \rightarrow \text{adresse\_f} \end{matrix}$$



Le schéma n'est pas 3FN!! (dépendance transitive entre num\_commande et adresse)

### 5.4 Normalisation 3FN

\* Lorsqu'un schéma relationnel n'est pas en troisième forme normale, il doit être normalisé:

#### Normalisation 3FN

- On crée une table pour chaque DFD trouvée au sein des attributs n'appartenant pas à la clé.

Soit  $R(\underline{A_1, \dots, A_m}, B_1, \dots, B_n)$  avec :  $A_1, \dots, A_m \stackrel{DFD}{\rightarrow} B_1, \dots, B_{j-1}, B_{j+1}, \dots, B_n$   
 $B_i \stackrel{DFD}{\rightarrow} B_j$  Alors :  $R_1(\underline{A_1, \dots, A_m}, B_1, \dots, B_{j-1}, B_{j+1}, \dots, B_n)$   $R_2(\underline{B_i}, B_j)$



#### Attention



Comme précédemment, il est important de **conserver** la clé primaire de la table initiale si elle permet d'associer les valeurs dispersées dans les tables.

#### Exemple :

Avant :

- **Commande** (num\_commande, nom\_f, adresse\_f, composant, quantité)
- avec :
  - num\_commande → nom\_f, composant, quantité
  - nom\_f → adresse\_f



Après :

- **Commande** (num\_commande, nom\_f, composant, quantité)
- **Client** (nom\_f, adresse\_f)

L'attribut nom\_f est maintenant clé primaire de la table Client et clé étrangère de la table Commande.

## 6. Modèle ensembliste



Pour leur conception, les bases de données sont ici vues comme des ensembles constitués de plusieurs populations d'objets *en interaction*, participant au bon fonctionnement d'un certain *système*. Établir un schéma de base de données consiste à décrire ces différentes populations d'objets, mais surtout et principalement à décrire les dépendances et les interactions entre ces populations.

Une base de donnée est constituée de plusieurs ensembles d'objets et d'opérateurs participant au bon fonctionnement d'un système:

### Exemple 1 :

- Ensembles d'employés
- Ensembles de commandes
- Ensembles d'articles
- Ensembles de clients

### Exemple 2 :

- Ensembles d'étudiants
- Ensembles de séances
- Ensembles de cours
- Ensembles de copies

On parle plus généralement d'**ensembles d'entités**.

### Le modèle entité/association



Le modèle entité/associations est une méthode de description des relations entre ensembles d'entités. Il s'appuie sur le prédicat selon lequel tous les éléments des ensembles d'entités sont discernables.

Le modèle entités/associations repose sur un langage graphique de description des données, indépendant du support et de la mise en œuvre informatique.

## Généralités

Une **entité** \$\$\$

- est une représentation d'un objet du monde réel,
- appartenant au système/à l'organisation modélisée.
- Une entité est décrite par une ou plusieurs valeurs caractéristiques, appelées **attributs**.

Les informations conservées au sujet des entités d'un ensemble sont les **attributs**.

- Chaque **attribut** :
  - a un **nom** unique dans le contexte de cet ensemble d'entités :  $A_1, A_2, \dots, A_m$ , ...
    - Exemples de noms concrets : *couleur, nom, horaire, salaire*.
  - prend ses valeurs dans un domaine bien spécifié,
    - également appelé le **type** de l'attribut.
    - Le domaine d'un attribut est noté  $\text{dom}(A_j) = D_j$ .
      - Exemples :
        - $\text{dom}(\text{couleur}) = \{\text{rouge, vert, bleu, jaune}\}$ ,
        - $\text{dom}(\text{nom}) = \text{ensemble des chaînes de caractères}$ ,
        - $\text{dom}(\text{salaire}) = \text{entiers naturels}$
        - etc...



- Un attribut  $A_j$  est une fonction à valeur sur  $D_j$  :

$$A_j : E \rightarrow D_j \quad x \mapsto A_j(x)$$



- Un attribut peut être :
  - simple ou composé.
    - Exemple : une *adresse* peut être décrite par une simple chaîne de caractères, ou peut être décomposée en *rue, no, boîte, ville, code postal, pays*.
  - obligatoire ou facultatif ( $D_j$  peut ou non contenir la valeur  $\emptyset$ ).
  - atomique ou non (Un attribut peut posséder 0, 1 voire plusieurs valeurs...)

Un **ensemble d'entités** est un ensemble fini d'éléments :  $E = \{x_1, \dots, x_n\}$  Il regroupe (ou associe) plusieurs entités ayant des caractéristiques communes (descriptibles à l'aide du même ensemble d'attributs).

### Exemples :




- les employés d'une firme,
- les cours de Centrale Méditerranée,
- une collection de disques,
- etc...

- Les éléments d'un ensemble d'entités sont *partiellement discernables* à travers les valeurs de leurs attributs :
  - les attributs  $(A_1, \dots, A_m)$  servent à décrire les éléments de l'ensemble.
  - Le schéma  $R$  de l'ensemble  $E$  est une *application* de l'ensemble d'entités vers l'ensemble des tuples de schéma  $R$ 
    - Soit :

$$R : \mathcal{X} \rightarrow D_1 \times \dots \times D_m \quad x_i \mapsto (A_1(x_i), \dots, A_m(x_i))$$

### représentation graphique :



Attributs

Ensemble d'entités


### Exemples :



### Définitions

Modéliser une base de données, c'est :

- Identifier les différents ensembles en interaction
- Identifier les liens de dépendance entre les différents ensembles





Les liens entre les différents ensembles sont appelés des **associations**

## Association

Une association exprime des relations de dépendance entre deux ou plusieurs ensembles d'entités.

**Définition** : Une **association** entre les ensembles  $E_1$ , ...,  $E_k$  est un sous-ensemble du produit  $E_1 \times \dots \times E_k$ .



Il s'agit donc d'un ensemble de k-uplets  $\{\dots, (x_1, \dots, x_k), \dots\}$  t.q.  $x_1 \in E_1, \dots, x_k \in E_k$ .

où  $k$  est le degré de l'association :

- $k=2$  : association binaire
- $k=3$  : association ternaire
- etc...

## Rôles des associations

- **Attribution** : propriété, réservation, participation, supervision, auteur, rôle, pilote, ...
- **Événements** : achat, vente, séance, épreuve, appel, consultation, réunion, transaction, transport ...
- **Aggrégation/Composition** : tout/parties, contenant/contenu, supérieur/subordonné, pays/région, ...
- **Relations entre membres** : parenté, collaboration, cercle d'amis, ...
- ...

### Contraintes de cardinalité



Pour chaque ensemble participant à une association, on précise dans combien d'instances de l'association chaque entité peut apparaître.

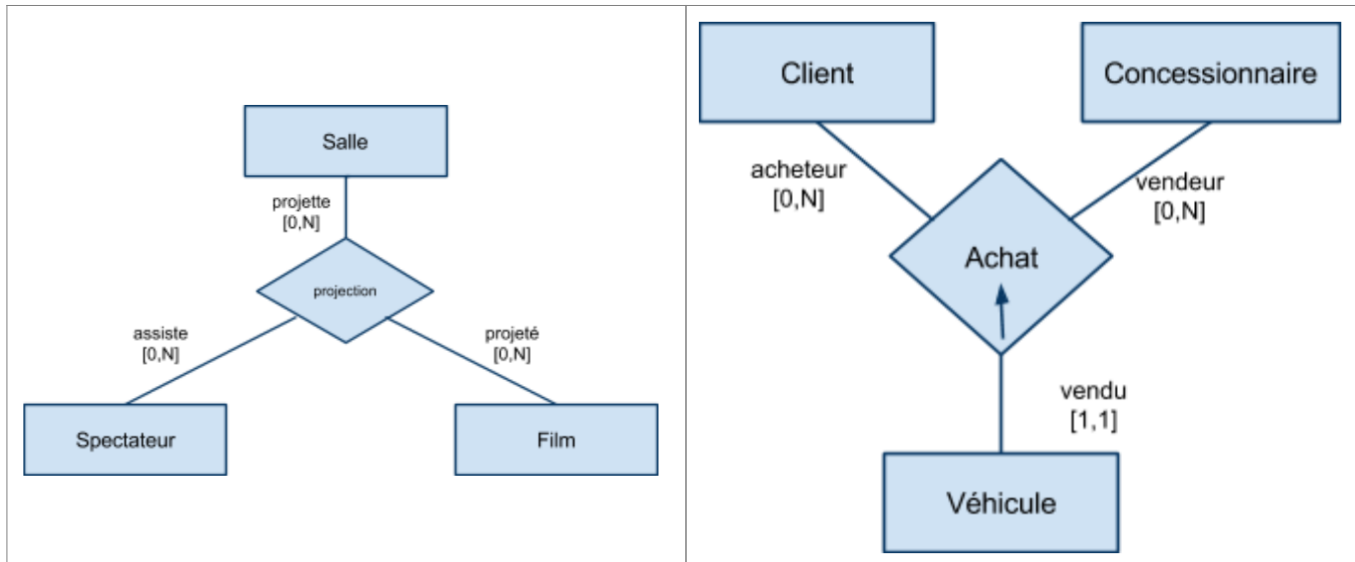
On donne en général un intervalle  $[b_{\text{inf}}, b_{\text{sup}}]$  qui définit le nombre d'apparitions autorisées pour chaque rôle de l'association

### Représentation graphique

#### Associations binaires



#### Associations ternaires



### Types d'associations


#### Associations de 1 à plusieurs (fonctionnelle)

Relation non symétrique entre les deux ensembles : [...,1] d'un côté, [...,N] de l'autre. Relation de type contenant/contenu, propriétaire/objet possédé, occupant/occupé, actif/passif etc... Il s'agit du type d'association le plus "courant".



On dit parfois que l'ensemble dont la participation est unique est dit "à gauche" de l'association fonctionnelle, et celui dont la participation est multiple est "à droite", autrement dit la pointe de la flèche désigne l'ensemble de "droite":

"à gauche" → "à droite"





### Associations de plusieurs à plusieurs (croisée)

Dans une association "croisée", les tous les lien de l'association sont de cardinalité multiple [...,N]



### Modèles Entité Associations valués

Dans le cadre du modèle entité/association :

- les attributs des ensembles d'entités sont des *mesures*:
  - Soit  $A$  un attribut de l'ensemble d'entités  $\mathcal{E}$



$A : \mathcal{E} \rightarrow \text{dom}(A)$

- les attributs des associations sont des *opérateurs* :
  - Soit  $B$  un attribut de l'association sur  $\mathcal{E} \times \mathcal{F}$

$B : \mathcal{E} \times \mathcal{F} \rightarrow \text{dom}(B)$

## Mesures

- Les mesures sont les données saisies sur les éléments d'un ensemble. Chaque mesure est associée à un attribut.
- Le schéma de l'ensemble est l'ensemble des attributs servant à caractériser ses éléments
- Les éléments de l'ensemble sont *discernables* ssi il existe un jeu de mesures différent pour chaque élément de l'ensemble
- Une *clé* est un ensemble d'attributs *minimal* (permettant de distinguer les objets) appartenant au schéma



### TODO

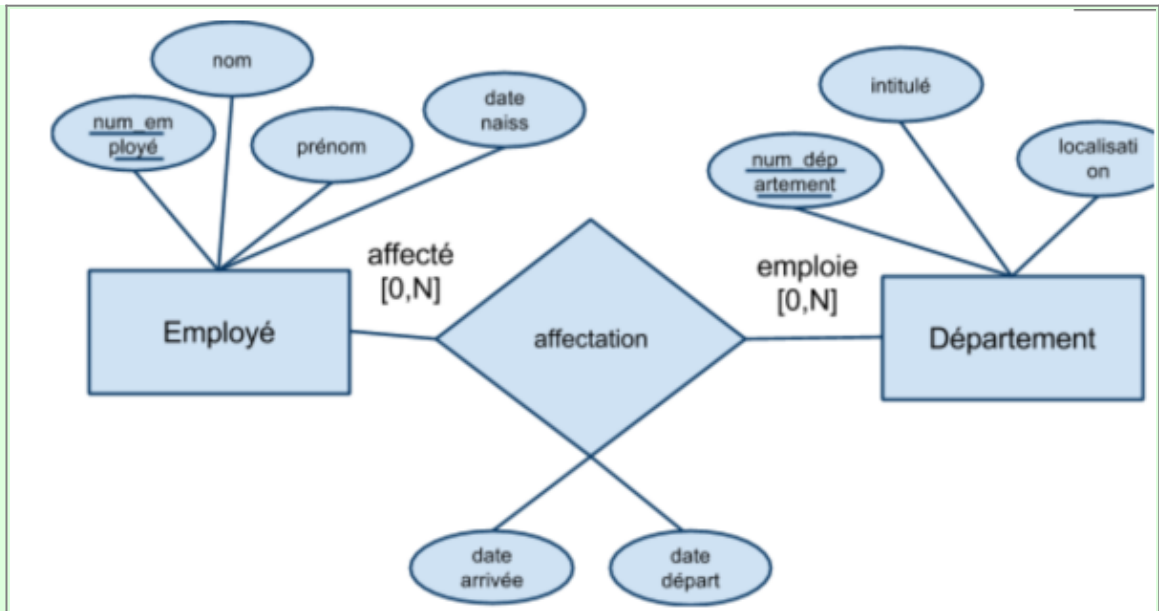
Ensembles discernables / non discernables

## Opérateurs

- On s'intéresse ici aux associations qui représentent une "opération" (inscription, achat, embauche, affectation...).
- Lors d'une mise à jour de la base, certains événements tels que l'emprunt ou le retour d'un ouvrage, l'affectation d'un employé à un poste, ou la liste des anciens clients disparaissent.
- Il est possible de garder une trace des événements passés en mettant un (ou plusieurs) attributs sur une association.
- Ainsi, certaines associations peuvent être "datées", c'est à dire
  - avoir lieu à une date
  - ou prendre place sur une durée précise (prêt, accès temporaire, statut temporaire...)
- On peut ainsi mémoriser :
  - "Monsieur Dupont a été employé au département logistique de tant à tant."...
  - "L'étudiant X a été élève Centrale Méditerranée de telle année à telle année"...

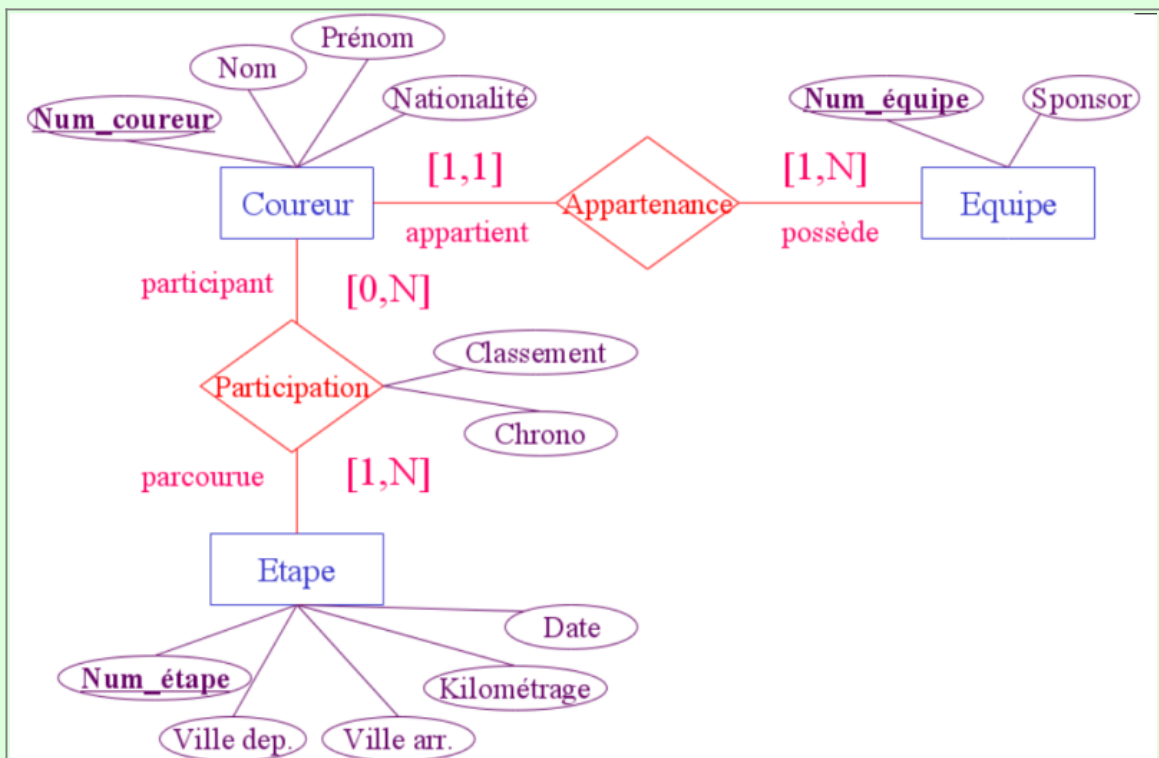


**Exemple** "Monsieur Dupont a été employé au département logistique de tant à tant."...



### Exemple

- Chaque coureur est décrit par ses nom, prénom, nationalité et numéro de maillot.
- Chaque coureur appartient à une équipe qui possède un numéro, un sponsor associé.
- Chaque coureur participe à une ou plusieurs étapes. Une étape se caractérise par son numéro, son type (contre la montre/étape simple), ses points de départ et d'arrivée, sa date.
- A chaque étape est associée un classement d'arrivée pour chaque coureur, avec la durée totale de course.



## 7. Traduction vers le modèle relationnel

Il est possible de traduire un modèle entité/association vers un modèle relationnel (en perdant quelques propriétés).

Lors de la réalisation d'une base de données, on passe en général par les étapes suivantes:



1. Conception de la base sous forme d'un modèle entité/association.
2. Traduction sous la forme d'un modèle relationnel.
3. Normalisation (voir [Normalisation d'un schéma](#))
4. Mise en œuvre informatique.

Un petit nombre de règles permettent de traduire un modèle entité/association vers un modèle relationnel.

- Selon ces règles, à la fois les ensembles d'entités et les associations sont transformés en schémas relationnels.
- Les liaisons et dépendances entre schémas de relation sont assurés par la définition des **clés étrangères** (attributs communs à plusieurs tables).

### Schéma de base et clé étrangère



- Un schéma (ou modèle) de bases de données est un ensemble fini de schémas de relation.
- Une base de données est un ensemble fini de relations.
- Les liens et associations entre relations entre s'expriment sous la forme de **clés étrangères**

### Définition



- Au sein d'un schéma relationnel  $R$ , Une clé étrangère est un attribut (ou un groupe d'attributs) qui constitue la clé primaire d'un schéma  $S$  distinct de  $R$ .
- La présence d'une clé étrangère au sein d'une relation  $r$  de schéma  $R$  introduit une contrainte d'intégrité sur les données :
  - la valeur des attributs de la clé étrangère d'un tuple de  $r$  doit être trouvée dans la table  $s$  correspondante.
- On indique la présence d'une clé étrangère à l'aide de pointillés :  $\{ \dots, \underline{\text{Clé étrangère}}, \dots \}$

### Exemple

### Schéma de base relationnelle :



- **Clients** ( nom\_client, adresse\_client, solde)
- **Commandes** ( num\_Commande, nom\_client, composant, quantité)
- **Fournisseurs** ( nom\_fournisseur, adresse\_fournisseur)
- **Catalogue** ( nom\_fournisseur, composant, prix )

### Traduction des associations de plusieurs à plusieurs


Une association croisée ne contient que des contraintes de cardinalité de type [...,N]. Soit \$R\$ une telle association et \$E\_1\$, ..., \$E\_k\$ les ensembles participant à l'association.

### Règle de traduction :



- Chaque ensemble \$E\_i\$ est traduit par un schéma relationnel (contenant les mêmes attributs)
- L'association \$R\$ est traduite sous la forme d'un schéma relationnel contenant:
  - les clés primaires des ensembles participant à l'association
  - (éventuellement) les attributs propres à l'association,

### Exemple :



### Traduction :

- **Pays** ( nom\_pays, superficie, population, PIB )
- **Matière première** ( nom\_matière, unité, prix )
- **Exportation** ( nom\_pays, nom\_matière, quantité)



**Traduction :**

- **Appareil** (code\_appareil, type, marque, modèle)
- **Séance** (date, heure, local)
- **Réservation** (code\_appareil, date, heure, local)

**Traduction des associations de un à plusieurs**

Soit une association fonctionnelle \$R\$. On suppose qu'il existe au moins un ensemble \$A\$ de cardinalité unique [1,1] participant l'association.

**Règle de traduction**

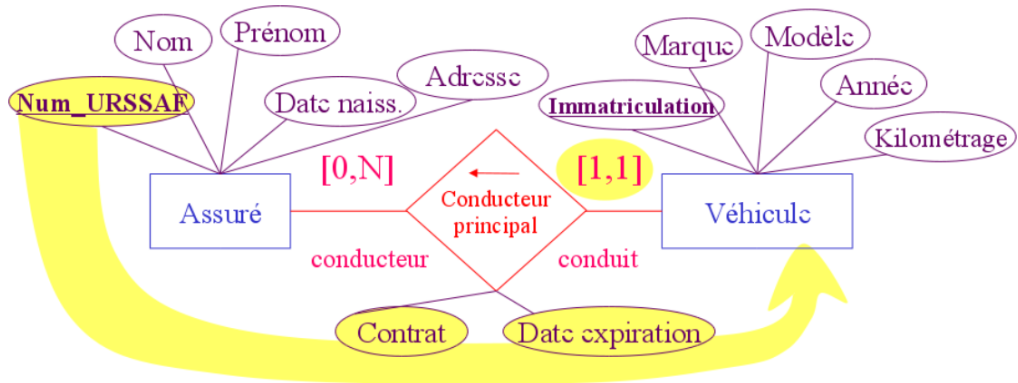


- Chaque ensemble participant est traduit sous forme de schéma relationnel
- L'association \$R\$ est traduite sous forme de **clé étrangère** : l'ensemble \$A\$ reçoit la clé primaire du (ou des) ensemble(s) dont la participation est multiple.

**Exemple**



**Remarque** : lorsque l'association est évaluée, les attributs de l'association sont également injectés dans la table représentant l'ensemble de gauche.



→ Assuré(num URSSAF, nom, prénom, date naiss, adresse)  
Véhicule(immatriculation, marque, modèle, année, kilométrage, num URSSAF, contrat, date expiration)

**Exemple**



**Traduction :**

- **Groupe\_TD**( num\_groupe, LV1, LV2)
- **Entreprise** ( nom\_entreprise, Adresse)
- **Etudiant** ( num\_etudiant, Nom, Prénom, Date\_naiss, num\_groupe, intitulé, date, durée, nom\_entreprise)

**Exemple complet**

**Schéma de base relationnelle :**

- **Clients** ( nom\_client, adresse\_client, solde)
- **Commandes** ( num\_Commande, nom\_client, composant, quantité, montant)
- **Fournisseurs** ( nom\_fournisseur, adresse\_fournisseur)
- **Catalogue** ( nom\_fournisseur, composant, prix )

**Réalisation :****Clients :**

<u>nom_client</u>	<u>adresse_client</u>	<u>solde</u>
Durand	7, rue des Lilas	335,00
Dubois	44, av. du Maréchal Louis	744,00
Duval	5, place du marché	33,00

**Commandes :**

<u>num_Commande</u>	<u>nom_client</u>	<u>composant</u>	<u>quantité</u>
6674	Dubois	micro controller	55
6637	Dubois	radio tuner	2
6524	Durand	transistor	4
6443	Duval	micro controller	7

**Fournisseurs :**

<u>nom_fournisseur</u>	<u>adresse_fournisseur</u>
Sage	33, College street, London
MoxCom	77 Ashley square, Mumbai

**Catalogue :**

<u>nom_fournisseur</u>	<u>composant</u>	<u>prix</u>
Sage	transistor	4,4
MoxCom	micro controller	3,7
MoxCom	radio tuner	7,0

From:

<https://wiki.centrale-med.fr/informatique/> - **WiKi informatique**

Permanent link:

[https://wiki.centrale-med.fr/informatique/tc\\_info:2024\\_cm\\_modeles?rev=1734559336](https://wiki.centrale-med.fr/informatique/tc_info:2024_cm_modeles?rev=1734559336)
Last update: **2024/12/18 23:02**