

Fondements des Bases de données : *relation exemple*

M1 - Informatique

Lhouari Nourine, Karima Ennaoui et *Simon Vilmin*.

Institut d'informatique, ISIMA

2020-2021

Slides inspirées du cours de Jean-Marc Petit :

<https://perso.liris.cnrs.fr/jmpetit/ferme/doku.php/teaching>

Construction par l'exemple

- ▶ Représentation « *par l'exemple* » d'ensemble de contraintes : on manipule des valeurs, visualisation plus simple des éventuels conflits, incohérences, mauvaise conception, ...
- ▶ Une « *bonne* » relation exemple par rapport à des contraintes :
 - ▷ doit *respecter* ces contraintes ... et *seulement* celles-ci !
 - ▷ on l'appelle une *relation d'Armstrong*.
 - ▷ pour nous, focus (encore) sur les *dépendances fonctionnelles*.
- ▶ Deux principaux domaines d'application :
 - ▷ Conception par l'exemple
 - ▷ Échantillonnage, compréhension des bases de données existantes
- ▶ Exemple introductif : les *nuages* !
 - ▷ Attributs, $R = \{Forme, Structure, Nom, Couleur\}$,
 - ▷ des DFs : $Forme, Structure \rightarrow Nom$; $Nom \rightarrow Forme$; $Couleur \rightarrow Structure$.

Relation exemple : ni pas assez

Forme	Structure	Nom	Couleur
couche	cristaux	cirrostratus	translucide
couche	c + g	altostratus	gris
mouton	c + g	cumulonimbus	gris
mouton	gouttelettes	cumulonimbus	blanc
enclume	gouttelettes	cumulonimbus	blanc
enclume	gouttelettes	cumulonimbus	noir

- $R = \{Forme, Structure, Nom, Couleur\}$, DFs : $Forme, Structure \rightarrow Nom$; $Nom \rightarrow Forme$; $Couleur \rightarrow Structure$.

Relation exemple : ni pas assez

Forme	Structure	Nom	Couleur
couche	cristaux	cirrostratus	translucide
couche	c + g	altostratus	gris
mouton	c + g	cumulonimbus	gris
mouton	gouttelettes	cumulonimbus	blanc
enclume	gouttelettes	cumulonimbus	blanc
enclume	gouttelettes	cumulonimbus	noir

► $R = \{Forme, Structure, Nom, Couleur\}$, DFs : $Forme, Structure \rightarrow Nom$; $Nom \rightarrow Forme$; $Couleur \rightarrow Structure$.

✗ La DF $Nom \rightarrow Forme$ n'est pas respectée !

Relation exemple : ni trop

Forme	Structure	Nom	Couleur
couche	cristaux	cirrostratus	translucide
couche	c + g	altostratus	gris
mouton	c + g	cumulonimbus	gris
mouton	gouttelettes	cumulonimbus	blanc
rouleaux	gouttelettes	altocumulus	b + g

- $R = \{Forme, Structure, Nom, Couleur\}$, DFs : $Forme, Structure \rightarrow Nom$; $Nom \rightarrow Forme$; $Couleur \rightarrow Structure$.

Relation exemple : ni trop

Forme	Structure	Nom	Couleur
couche	cristaux	cirrostratus	translucide
couche	c + g	altostratus	gris
mouton	c + g	cumulonimbus	gris
mouton	gouttelettes	cumulonimbus	blanc
rouleaux	gouttelettes	altocumulus	b + g

► $R = \{Forme, Structure, Nom, Couleur\}$, DFs : $Forme, Structure \rightarrow Nom$; $Nom \rightarrow Forme$; $Couleur \rightarrow Structure$.

✓ La relation satisfait les DFs

Relation exemple : ni trop

Forme	Structure	Nom	Couleur
couche	cristaux	cirrostratus	translucide
couche	c + g	altostratus	gris
mouton	c + g	cumulonimbus	gris
mouton	gouttelettes	cumulonimbus	blanc
rouleaux	gouttelettes	altocumulus	b + g

- ▶ $R = \{Forme, Structure, Nom, Couleur\}$, DFs : $Forme, Structure \rightarrow Nom$; $Nom \rightarrow Forme$; $Couleur \rightarrow Structure$.
- ✓ La relation satisfait les DFs
- ✗ mais $Forme, Structure \rightarrow Nom, Couleur$ est aussi valide ($Forme, Structure$ est une clé)!

Relation exemple : juste ce qu'il faut

Forme	Structure	Nom	Couleur
couche	cristaux	cirrostratus	translucide
couche	c + g	altostratus	gris
mouton	c + g	cumulonimbus	gris
mouton	gouttelettes	cumulonimbus	blanc
mouton	gouttelettes	cumulonimbus	noir

- $R = \{Forme, Structure, Nom, Couleur\}$, DFs : $Forme, Structure \rightarrow Nom$; $Nom \rightarrow Forme$; $Couleur \rightarrow Structure$.

Relation exemple : juste ce qu'il faut

Forme	Structure	Nom	Couleur
couche	cristaux	cirrostratus	translucide
couche	c + g	altostratus	gris
mouton	c + g	cumulonimbus	gris
mouton	gouttelettes	cumulonimbus	blanc
mouton	gouttelettes	cumulonimbus	noir

- ▶ $R = \{Forme, Structure, Nom, Couleur\}$, DFs : $Forme, Structure \rightarrow Nom$; $Nom \rightarrow Forme$; $Couleur \rightarrow Structure$.
- ✓ La relation satisfait les DFs


Relation exemple : juste ce qu'il faut

Forme	Structure	Nom	Couleur
couche	cristaux	cirrostratus	translucide
couche	c + g	altostratus	gris
mouton	c + g	cumulonimbus	gris
mouton	gouttelettes	cumulonimbus	blanc
mouton	gouttelettes	cumulonimbus	noir

- ▶ $R = \{Forme, Structure, Nom, Couleur\}$, DFs : $Forme, Structure \rightarrow Nom$; $Nom \rightarrow Forme$; $Couleur \rightarrow Structure$.
- ✓ La relation satisfait les DFs
- ✓ et aucune autre qui ne découle pas de celles de départ

Dans l'épisode précédent


- ▶ Les *contraintes d'intégrité* définissent ce qu'est une bonne base de données,
- ▶ Σ ensemble de *dépendances fonctionnelles* (DFs) $X \rightarrow Y$ sur un schéma de relation R ,
- ▶ $\Sigma \models X \rightarrow Y$ est l'*implication logique* : « on déduit $X \rightarrow Y$ à partir de Σ ».
- ▶ $X^\Sigma = \{A \in R \mid \Sigma \models X \rightarrow A\}$, pour tout $X \subseteq R$ (algo de *fermeture*).



- ▶ $\Sigma = \{AB \rightarrow D, CD \rightarrow F, DE \rightarrow G\}$,
- ▶ $ABE^\Sigma = ABDEG$.

Dans l'épisode précédent


- ▶ Les *contraintes d'intégrité* définissent ce qu'est une bonne base de données,
- ▶ Σ ensemble de *dépendances fonctionnelles* (DFs) $X \rightarrow Y$ sur un schéma de relation R ,
- ▶ $\Sigma \models X \rightarrow Y$ est l'*implication logique* : « on déduit $X \rightarrow Y$ à partir de Σ ».
- ▶ $X^\Sigma = \{A \in R \mid \Sigma \models X \rightarrow A\}$, pour tout $X \subseteq R$ (algo de *fermeture*).



- ▶ $\Sigma = \{AB \rightarrow D, CD \rightarrow F, DE \rightarrow G\}$,
- ▶ $ABE^\Sigma = ABDEG$.

Dans l'épisode précédent

- ▶ Les *contraintes d'intégrité* définissent ce qu'est une bonne base de données,
- ▶ Σ ensemble de *dépendances fonctionnelles* (DFs) $X \rightarrow Y$ sur un schéma de relation R ,
- ▶ $\Sigma \models X \rightarrow Y$ est l'*implication logique* : « on déduit $X \rightarrow Y$ à partir de Σ ».
- ▶ $X^\Sigma = \{A \in R \mid \Sigma \models X \rightarrow A\}$, pour tout $X \subseteq R$ (algo de *fermeture*).



- ▶ $\Sigma = \{AB \rightarrow D, CD \rightarrow F, DE \rightarrow G\}$,
- ▶ $ABE^\Sigma = ABDEG$.

Relation d'Armstrong


Définition - Relation d'Armstrong

Soit Σ un ensemble de DFs sur R . Une relation r sur R est une *relation d'Armstrong* (relation exemple) pour Σ si pour toute DF $X \rightarrow Y$:

$$\Sigma \models X \rightarrow Y \text{ si et seulement si } r \models X \rightarrow Y$$


- ▶ Une relation d'Armstrong pour Σ satisfait Σ et *rien d'autre*.
- ▶ Les relations d'Armstrong *existent aussi* pour les autres types de contraintes !

Exemple



► Où est la relation d'Armstrong de $\Sigma = \{D \rightarrow B, AB \rightarrow C, C \rightarrow A\}$?

Exemple



► Où est la relation d'Armstrong de $\Sigma = \{D \rightarrow B, AB \rightarrow C, C \rightarrow A\}$?

- ▶ **Question** : peut-on trouver une relation d'Armstrong pour n'importe quel Σ ?


- ▶ **Question** : peut-on trouver une relation d'Armstrong pour n'importe quel Σ ?

OUI !!!

- ▶ Il existe même une procédure « *algorithmique* » pour le faire !
- ▶ Hypothèse : pas de DFs $\emptyset \rightarrow X$, domaines infinis.

Théorème (Armstrong 1974) : Soit Σ un ensemble de DFs sur R . Il existe une relation d'Armstrong r pour Σ .

Armstrong wars : Épisode I



?

?

?

	A	B	C	D
t_0	1	a	x	0
t_1	1	b	y	2
t_2	3	b	z	2
t_3	3	c	z	4
t_4	3	c	z	6

Opérateur de fermeture

Définition - Opérateur de fermeture

Soit $\phi: 2^R \rightarrow 2^R$ une application. On dit que ϕ est un *opérateur de fermeture* (ou simplement une *fermeture*) si pour tout $X, Y \subseteq R$:

- ▶ $X \subseteq \phi(X)$ (*extensive*),
- ▶ si $X \subseteq Y$ alors $\phi(X) \subseteq \phi(Y)$ (*monotone*),
- ▶ $\phi(\phi(X)) = \phi(X)$ (*idempotente*).

▶ **Exercice** : les applications suivantes sont-elles des fermetures ?

- ▶ Pour tout $X \subseteq R$, $\phi(X) = R$.
- ▶ Soit $Y \subseteq R$. Pour tout $X \subseteq R$, $\phi(X) = X \cap Y$.
- ▶ Soit $Y \subseteq R$. Pour tout $X \subseteq R$, $\phi(X) = X \cup Y$.
- ▶ Soit $G = (V, E)$ un graphe. Pour tout $X \subseteq V$,
 $\phi(X) = X \cup \{u \in V \mid \exists x \in X \text{ tel que } (x, u) \in E\}$.

Définition - Système de fermeture

Soit $\mathcal{F} \subseteq 2^R$ une *famille d'ensembles sur R*. On dit que \mathcal{F} est un *système de fermeture*, et ses éléments sont des *fermés*, si :


- ▶ $R \in \mathcal{F}$,
 - ▶ $F_1, F_2 \in \mathcal{F}$ implique que $F_1 \cap F_2 \in \mathcal{F}$.
-
- ▶ Les systèmes de fermeture sont partout !
 - ▷ logique, data mining (FCA), base de données
 - ▷ géométrie, optimisation, graphes, ...

Exemple (fil rouge)


► Parmi ces exemples, un est un système de fermeture :

- ▷ $\mathcal{F}_1 = \{\emptyset, A, B, CD, ABCD\}$,
- ▷ $\mathcal{F}_2 = \{\emptyset, A, B, ABC, ABD, ABCD\}$,
- ▷ $\mathcal{F}_3 = \{\emptyset, A, B, C, AB, ACD, BCD\}$


$(\mathcal{F}_1, \subseteq)$



$(\mathcal{F}_2, \subseteq)$



$(\mathcal{F}_3, \subseteq)$




Exemple (fil rouge)


► Parmi ces exemples, un est un système de fermeture :

- ▷ $\mathcal{F}_1 = \{\emptyset, A, B, CD, ABCD\}$,
- ▷ $\mathcal{F}_2 = \{\emptyset, A, B, ABC, ABD, ABCD\}$,
- ▷ $\mathcal{F}_3 = \{\emptyset, A, B, C, AB, ACD, BCD\}$


$(\mathcal{F}_1, \subseteq)$



$(\mathcal{F}_2, \subseteq)$



$(\mathcal{F}_3, \subseteq)$



Propriétés

- ▶ Une fermeture est associé à un *unique* système de fermeture.
- ▶ Un système de fermeture est associé à un *unique* opérateur de fermeture.
- ▶ Autrement dit : ce sont deux *représentations* d'une *même information* !

Propriété : Soit ϕ une fermeture sur R . Alors la collection $\mathcal{F}_\phi = \{X \subseteq R \mid \phi(X) = X\}$ est un système de fermeture.

Propriété : Soit \mathcal{F} un système de fermeture sur R . Alors l'opérateur $\phi_{\mathcal{F}}$ telle que $\phi_{\mathcal{F}}(X) = \bigcap \{F \in \mathcal{F} \mid X \subseteq F\}$ est une fermeture.



Le rapport avec nos DFs

- ▶ L'opérateur $(\cdot)^\Sigma$ associé à un Σ est une *fermeture*!
- ▶ Donc, la collection des fermés de Σ


$$\mathcal{F}_\Sigma = \{X^\Sigma \mid X \subseteq R\} = \{X \subseteq R \mid X = X^\Sigma\}$$

est un *système de fermeture*!

Propriété : Soit Σ un ensemble de DFs. La famille \mathcal{F}_Σ est un système de fermeture.



Armstrong wars : Épisode II




?

?

?

	A	B	C	D
t_0	1	a	x	0
t_1	1	b	y	2
t_2	3	b	z	2
t_3	3	c	z	4
t_4	3	c	z	6

Armstrong wars : Épisode II




	A	B	C	D
t_0	1	a	x	0
t_1	1	b	y	2
t_2	3	b	z	2
t_3	3	c	z	4
t_4	3	c	z	6

Définition - Infs-irréductibles, MAX-SETS

Soit \mathcal{F} un système de fermeture sur R , et $M \in \mathcal{F}$, $M \neq R$. On dit que M est un *inf-irréductible* (ou *MAX-SET*) si quelque soit $F_1, F_2 \in \mathcal{F}$, $M = F_1 \cap F_2$ implique que $M = F_1$ ou $M = F_2$. Les inf-irréductibles de \mathcal{F} sont notés \mathcal{M} .

- ▶ Dans \mathcal{F} , certains éléments sont obtenus par l'*intersection* d'autres, ils sont *redondants* et donc *réductibles*.
- ▶ Quand on enlève tous ces éléments redondants, il reste ceux qu'on ne peut pas obtenir par intersection : ce sont les *infs-irréductibles*!
- ▶ Autrement dit : \mathcal{M} est la partie « génératrice » de \mathcal{F} , on peut *reconstruire* tout \mathcal{F} depuis \mathcal{M} (par \cap).
- ▶ \mathcal{M} concentre toute la « connaissance » de \mathcal{F} .


Exemple (fil rouge)



▶ $\mathcal{F} = \{\emptyset, A, B, AC, ABC, BD, ABCD\}$,


▶

Exemple (fil rouge)




- ▶ $\mathcal{F} = \{\emptyset, A, B, AC, ABC, BD, ABCD\}$,
- ▶ $ABCD$ n'est *pas* inf-irréductible par définition

Exemple (fil rouge)




- ▶ $\mathcal{F} = \{\emptyset, A, B, AC, ABC, BD, ABCD\}$,
- ▶ $ABCD$ n'est *pas* inf-irréductible par définition

Exemple (fil rouge)




- ▶ $\mathcal{F} = \{\emptyset, A, B, AC, ABC, BD, ABCD\}$,
- ▶ \emptyset est l'intersection de A et B , il n'est *pas* inf-irréductible

Exemple (fil rouge)




- ▶ $\mathcal{F} = \{\emptyset, A, B, AC, ABC, BD, ABCD\}$,
- ▶ \emptyset est l'intersection de A et B , il n'est *pas* inf-irréductible

Exemple (fil rouge)



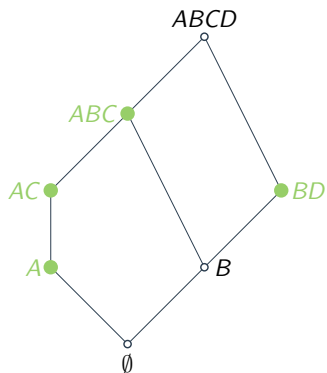
- ▶ $\mathcal{F} = \{\emptyset, A, B, AC, ABC, BD, ABCD\}$,
- ▶ B est l'intersection de ABC et BD , il n'est *pas* inf-irréductible

Exemple (fil rouge)



- ▶ $\mathcal{F} = \{\emptyset, A, B, AC, ABC, BD, ABCD\}$,
- ▶ B est l'intersection de ABC et BD , il n'est *pas* inf-irréductible

Exemple (fil rouge)



- ▶ $\mathcal{F} = \{\emptyset, A, B, AC, ABC, BD, ABCD\}$,
- ▶ Au final, les infs-irréductibles sont A, AC, ABC, BD .


Propriétés

- ▶ Soit \mathcal{F} un système de fermeture sur R , et $A \in R$.
- ▶ On définit $MAX(A) = \max_{\subseteq} \{F \in \mathcal{F} \mid A \notin F\}$.
- ▶ En d'autres termes : M est dans $MAX(A)$ s'il *ne contient pas* A et si quelque soit le fermé M' « au dessus » de M ($M \subseteq M'$), M' contient A .

Propriété : Pour tout $A \in R$, $MAX(A) \subseteq \mathcal{M}$. De plus, $\mathcal{M} = \bigcup_{A \in R} MAX(A)$.

- ▶ Considérons C , son fermé est AC .

- ▶
- ▶




Propriétés

- ▶ Soit \mathcal{F} un système de fermeture sur R , et $A \in R$.
- ▶ On définit $MAX(A) = \max_{\subseteq} \{F \in \mathcal{F} \mid A \notin F\}$.
- ▶ En d'autres termes : M est dans $MAX(A)$ s'il *ne contient pas* A et si quelque soit le fermé M' « au dessus » de M ($M \subseteq M'$), M' contient A .

Propriété : Pour tout $A \in R$, $MAX(A) \subseteq \mathcal{M}$. De plus, $\mathcal{M} = \bigcup_{A \in R} MAX(A)$.

- ▶ Considérons C , son fermé est AC .
- ▶ $AC, ABC, ABCD$ ne *sont pas intéressants* (ils ont C),
- ▶




Propriétés

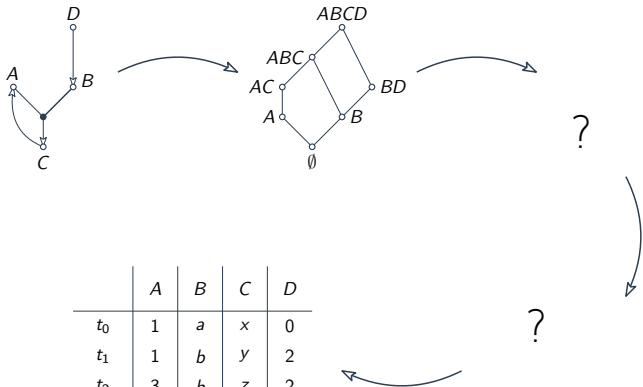
- ▶ Soit \mathcal{F} un système de fermeture sur R , et $A \in R$.
- ▶ On définit $MAX(A) = \max_{\subseteq} \{F \in \mathcal{F} \mid A \notin F\}$.
- ▶ En d'autres termes : M est dans $MAX(A)$ s'il *ne contient pas* A et si quelque soit le fermé M' « au dessus » de M ($M \subseteq M'$), M' contient A .

Propriété : Pour tout $A \in R$, $MAX(A) \subseteq \mathcal{M}$. De plus, $\mathcal{M} = \bigcup_{A \in R} MAX(A)$.

- ▶ Considérons C , son fermé est AC .
- ▶ $AC, ABC, ABCD$ ne *sont pas intéressants* (ils ont C),
- ▶ Les *maximaux restants* sont A et BD




Armstrong wars : Épisode III



	A	B	C	D
t_0	1	a	x	0
t_1	1	b	y	2
t_2	3	b	z	2
t_3	3	c	z	4
t_4	3	c	z	6

Armstrong wars : Épisode III



	A	B	C	D
t_0	1	a	x	0
t_1	1	b	y	2
t_2	3	b	z	2
t_3	3	c	z	4
t_4	3	c	z	6

?

Agrées

- **Idée** : deux tuples d'une relation r respectent forcément les DFs de r . Donc, si on compare ces tuples et que l'on note les attributs sur lesquels ils sont en *en accord* (égaux), on obtient un *fermé* des DFs de r !

Définition - Agree set

Soit r une relation sur R et $t, t' \in r$. L'*agree set* de t, t' , noté $ag(t, t')$ est l'ensemble des attributs de R sur lesquels t et t' sont égaux, c.à.d, $ag(t, t') = \{A \in R \mid t[A] = t'[A]\}$. L'ensemble des agree sets de r est noté $ag(r)$.

	A	B	C	D
t_0	1	a	x	0
t_1	1	b	y	2
t_2	3	b	z	2
t_3	3	c	z	4
t_4	3	c	z	6

Agrées

- **Idée** : deux tuples d'une relation r respectent forcément les DFs de r . Donc, si on compare ces tuples et que l'on note les attributs sur lesquels ils sont en *en accord* (égaux), on obtient un *fermé* des DFs de r !

Définition - Agree set

Soit r une relation sur R et $t, t' \in r$. L'*agree set* de t, t' , noté $ag(t, t')$ est l'ensemble des attributs de R sur lesquels t et t' sont égaux, c.à.d, $ag(t, t') = \{A \in R \mid t[A] = t'[A]\}$. L'ensemble des agree sets de r est noté $ag(r)$.

	A	B	C	D
t_0	1	a	x	0
t_1	1	b	y	2
t_2	3	b	z	2
t_3	3	c	z	4
t_4	3	c	z	6

Agrées

- **Idée** : deux tuples d'une relation r respectent forcément les DFs de r . Donc, si on compare ces tuples et que l'on note les attributs sur lesquels ils sont en *en accord* (égaux), on obtient un *fermé* des DFs de r !

Définition - Agree set

Soit r une relation sur R et $t, t' \in r$. L'*agree set* de t, t' , noté $ag(t, t')$ est l'ensemble des attributs de R sur lesquels t et t' sont égaux, c.à.d. $ag(t, t') = \{A \in R \mid t[A] = t'[A]\}$. L'ensemble des agree sets de r est noté $ag(r)$.

	A	B	C	D
t_0	1	a	x	0
t_1	1	b	y	2
t_2	3	b	z	2
t_3	3	c	z	4
t_4	3	c	z	6

$$ag(t_2, t_4) = AC$$

Le super théorème

Théorème : Soit Σ un ensemble de DFs et r une relation sur R . Alors, r est une relation d'Armstrong pour Σ si et seulement si $\mathcal{M} \subseteq ag(r) \subseteq \mathcal{F}$.

- ▶ Première idée de construction :
 - ▶ pour chaque $M \in \mathcal{M}$, on crée deux tuples t_M^1, t_M^2 qui codent exactement M (agree set);
 - ▶ pour tout $M' \neq M$, on garantit que $ag(t_M^i, t_{M'}^j) = \emptyset$ en faisant en sorte que les valeurs utilisées pour coder M soient disjointes de celles utilisées pour coder M' ;
 - ▶ on obtient une relation avec $2 \times |\mathcal{M}|$ tuples.
- ▶ On peut faire mieux : en $|\mathcal{M}| + 1$ tuples.

Algo relation d'Armstrong

Algorithme ARMSTRONG(\mathcal{M})

Data: \mathcal{M} un ensemble d'infs sur R

Result: r , une relation d'Armstrong

// Pour tout $A \in R$, on fixe $\text{dom}(A) = \mathbb{N}$

foreach $A \in R$ **do** $t_0[A] := 0$ **end**

$r := \{t_0\};$

$i := 1;$

foreach $M \in \mathcal{M}$ **do**

foreach $A \in R$ **do**

if $A \in M$ **then** $t_i[A] := t_{i-1}[A];$

else $t_i[A] := t_{i-1}[A] + 1;$

end

$r := r \cup t_i;$

$i := i + 1;$

end

return $r;$

Trace sur un exemple (fil rouge)

\mathcal{M}		<i>A</i>	<i>B</i>	<i>C</i>	<i>D</i>
	t_0	0	0	0	0
<i>A</i>					
<i>BD</i>					
<i>AC</i>					
<i>ABC</i>					

Trace sur un exemple (fil rouge)

\mathcal{M}		A	B	C	D
	t_0	0	0	0	0
A	t_1	0	1	1	1
BD					
AC					
ABC					

Trace sur un exemple (fil rouge)

\mathcal{M}		<i>A</i>	<i>B</i>	<i>C</i>	<i>D</i>
	t_0	0	0	0	0
	t_1	0	1	1	1

BD
AC
ABC

$\boxed{} \quad ag(t_0, t_1) = A$

Trace sur un exemple (fil rouge)

\mathcal{M}		A	B	C	D
	t_0	0	0	0	0
	t_1	0	1	1	1
<i>BD</i>	t_2	1	1	2	1
<i>AC</i>					
<i>ABC</i>					

Trace sur un exemple (fil rouge)

\mathcal{M}		A	B	C	D	
	t_0	0	0	0	0	
	t_1	0	1	1	1] $ag(t_1, t_2) = BD$
	t_2	1	1	2	1	
AC						
ABC						

Trace sur un exemple (fil rouge)

\mathcal{M}		<i>A</i>	<i>B</i>	<i>C</i>	<i>D</i>
	t_0	0	0	0	0
	t_1	0	1	1	1
	t_2	1	1	2	1
<i>AC</i>	t_3	1	2 ⁺¹	2	2 ⁺¹
<i>ABC</i>					

Trace sur un exemple (fil rouge)

\mathcal{M}		A	B	C	D	
	t_0	0	0	0	0	
	t_1	0	1	1	1	
	t_2	1	1	2	1] $ag(t_2, t_3) = AC$
ABC	t_3	1	2	2	2	

Trace sur un exemple (fil rouge)

\mathcal{M}		<i>A</i>	<i>B</i>	<i>C</i>	<i>D</i>
	t_0	0	0	0	0
	t_1	0	1	1	1
	t_2	1	1	2	1
	t_3	1	2	2	2
<i>ABC</i>	t_4	1	2	2	3

Trace sur un exemple (fil rouge)

\mathcal{M}

	A	B	C	D
t_0	0	0	0	0
t_1	0	1	1	1
t_2	1	1	2	1
t_3	1	2	2	2
t_4	1	2	2	3

$\square \quad ag(t_3, t_4) = ABC$

Trace sur un exemple (fil rouge)

	<i>A</i>	<i>B</i>	<i>C</i>	<i>D</i>
t_0	0	0	0	0
t_1	0	1	1	1
t_2	1	1	2	1
t_3	1	2	2	2
t_4	1	2	2	3

Trace sur un exemple (fil rouge)

	<i>A</i>	<i>B</i>	<i>C</i>	<i>D</i>
t_0	1	<i>a</i>	<i>x</i>	0
t_1	1	<i>b</i>	<i>y</i>	2
t_2	3	<i>b</i>	<i>z</i>	2
t_3	3	<i>c</i>	<i>z</i>	4
t_4	3	<i>c</i>	<i>z</i>	6




Trace sur un exemple (fil rouge)

	<i>A</i>	<i>B</i>	<i>C</i>	<i>D</i>
t_0	1	<i>a</i>	<i>x</i>	0
t_1	1	<i>b</i>	<i>y</i>	2
t_2	3	<i>b</i>	<i>z</i>	2
t_3	3	<i>c</i>	<i>z</i>	4
t_4	3	<i>c</i>	<i>z</i>	6



Théorème : Soit Σ un ensemble de DFs et \mathcal{M} ses infs-irréductibles. L'algorithme ARMSTRONG(\mathcal{M}) calcule une relation d'Armstrong pour Σ .


Armstrong wars : Épisode IV



	A	B	C	D
t_0	1	a	x	0
t_1	1	b	y	2
t_2	3	b	z	2
t_3	3	c	z	4
t_4	3	c	z	6

?


Armstrong wars : Épisode IV



	A	B	C	D
t_0	1	a	x	0
t_1	1	b	y	2
t_2	3	b	z	2
t_3	3	c	z	4
t_4	3	c	z	6

Algo + Thm

Armstrong wars : Épisode IV



On peut le faire à l'envers !

	A	B	C	D
t_0	1	a	x	0
t_1	1	b	y	2
t_2	3	b	z	2
t_3	3	c	z	4
t_4	3	c	z	6



Algo + Thm

Formellement

- ▶ On part d'un ensemble de DFs Σ ,
- ▶ on calcule la collection de ses fermés \mathcal{F} ,
- ▶ on en déduit les infs-irréductibles \mathcal{M} ,
- ▶ en utilisant \mathcal{M} , théorème des agrées et l'algorithme ARMSTRONG, on peut calculer une relation d'Armstrong r pour Σ .

La suite : correction d'une relation

- ▶ Ce qu'on a vu : comment *construire* une relation exemple qui satisfait un ensemble de DFs et *seulement* celles-ci.
- ▶ Ce qu'on va voir : comment *corriger* une relation pour qu'elle satisfasse des DFs, quitte à en satisfaire d'autres.
- ▶ Soit r une relation, Σ des DFs et $r \not\models \Sigma$. Principe :
 - ▷ r doit contenir un *contre-exemple* à Σ , c.à.d, une paire de tuples t, t' telle que $ag(t, t') \notin \mathcal{F}$.
 - ▷ donc, on va *corriger* ce contre-exemple en changeant les valeurs, et répéter cette opération jusqu'à ce qu'aucun contre-exemple ne subsiste.

Algorithme CHASE(Σ, r)

Data: Σ un ensemble de DF sur R , r une relation

Result: une relation r' telle que $r' \models \Sigma$


Tant que c'est possible, appliquer la règle suivante :

Soit $X \rightarrow Y \in \Sigma$ et $t, t' \in r$

if $t[X] = t'[X]$ et il existe $A \in Y$ tel que $t[A] \neq t'[A]$ **then**
 $t[A] := t'[A] := \min(t[A], t'[A]);$


Exemple

	<i>A</i>	<i>B</i>	<i>C</i>	<i>D</i>
t_0	1	<i>a</i>	<i>x</i>	0
t_1	1	<i>b</i>	<i>y</i>	2
t_2	3	<i>b</i>	<i>z</i>	2
t_3	3	<i>c</i>	<i>z</i>	4
t_4	5	<i>c</i>	<i>z</i>	4
t_5	5	<i>c</i>	<i>z</i>	6




Exemple

	<i>A</i>	<i>B</i>	<i>C</i>	<i>D</i>
t_0	1	<i>a</i>	<i>x</i>	0
t_1	1	<i>b</i>	<i>y</i>	2
t_2	3	<i>b</i>	<i>z</i>	2
t_3	3	<i>c</i>	<i>z</i>	4
t_4	5	<i>c</i>	<i>z</i>	4
t_5	5	<i>c</i>	<i>z</i>	6




Exemple

	<i>A</i>	<i>B</i>	<i>C</i>	<i>D</i>
t_0	1	<i>a</i>	<i>x</i>	0
t_1	1	<i>b</i>	<i>y</i>	2
t_2	3	<i>b</i>	<i>z</i>	2
t_3	3	<i>c</i>	<i>z</i>	4
t_4	3	<i>c</i>	<i>z</i>	4
t_5	5	<i>c</i>	<i>z</i>	6




Exemple

	<i>A</i>	<i>B</i>	<i>C</i>	<i>D</i>
t_0	1	<i>a</i>	<i>x</i>	0
t_1	1	<i>b</i>	<i>y</i>	2
t_2	3	<i>b</i>	<i>z</i>	2
t_3	3	<i>c</i>	<i>z</i>	4
t_4	3	<i>c</i>	<i>z</i>	4
t_5	5	<i>c</i>	<i>z</i>	6




Exemple

	<i>A</i>	<i>B</i>	<i>C</i>	<i>D</i>
t_0	1	<i>a</i>	<i>x</i>	0
t_1	1	<i>b</i>	<i>y</i>	2
t_2	3	<i>b</i>	<i>z</i>	2
t_3	3	<i>c</i>	<i>z</i>	4
t_4	3	<i>c</i>	<i>z</i>	4
t_5	5	<i>c</i>	<i>z</i>	6




Exemple

	<i>A</i>	<i>B</i>	<i>C</i>	<i>D</i>
t_0	1	<i>a</i>	<i>x</i>	0
t_1	1	<i>b</i>	<i>y</i>	2
t_2	3	<i>b</i>	<i>z</i>	2
t_3	3	<i>c</i>	<i>z</i>	4
t_4	3	<i>c</i>	<i>z</i>	4
t_5	3	<i>c</i>	<i>z</i>	6




Exemple

	<i>A</i>	<i>B</i>	<i>C</i>	<i>D</i>
t_0	1	<i>a</i>	<i>x</i>	0
t_1	1	<i>b</i>	<i>y</i>	2
t_2	3	<i>b</i>	<i>z</i>	2
t_3	3	<i>c</i>	<i>z</i>	4
t_4	3	<i>c</i>	<i>z</i>	4
t_5	3	<i>c</i>	<i>z</i>	6




Exemple

	<i>A</i>	<i>B</i>	<i>C</i>	<i>D</i>
t_0	1	<i>a</i>	<i>x</i>	0
t_1	1	<i>b</i>	<i>y</i>	2
t_2	3	<i>b</i>	<i>z</i>	2
t_3	3	<i>c</i>	<i>z</i>	4
t_5	3	<i>c</i>	<i>z</i>	6



Exemple

	A	B	C	D
t_0	1	a	x	0
t_1	1	b	y	2
t_2	3	b	z	2
t_3	3	c	z	4
t_5	3	c	z	6



Théorème : L'algorithme $\text{CHASE}(\Sigma, r)$ s'arrête, et la relation résultat r' satisfait Σ .

Que peut-on faire d'autre avec Chase ?

- ▶ Tester en partie la « qualité » d'une décomposition de R :
 - ✓ Décomposition sans perte de *données* (jointures)
 - ✗ Décomposition sans perte de *dépendances fonctionnelles* (projection des DFs)
- ▶ Calculer la fermeture d'un ensemble d'attributs par rapport à Σ ,
- ▶ Tester l'implication logique (tableaux).

Algorithme de calcul de fermeture

Algorithme FERMETURE(X, Σ)

Data: $X \subseteq R$; Σ un ensemble de DF sur R

Result: X^Σ , la fermeture de X par rapport à Σ

$X^\Sigma := X$;

fini := *false*;

On construit une relation $r = t, t'$ avec $t[X] = t'[X]$ et $t[A] \neq t'[A]$ pour tout $A \notin X$;

$r' = \text{CHASE}(r, \Sigma)$;

if $|r'| = 2$ **then**

 | $X^\Sigma = \text{ag}(t, t')$

else


 | $X^\Sigma = R$

end

return X^Σ ;

Trace sur un exemple

	A	B	C	D	E	F	G
t							
t'							




► Soit $\Sigma = \{AB \rightarrow D, CD \rightarrow F, DE \rightarrow G\}$. On cherche ABE^{Σ} .

►

Trace sur un exemple

	A	B	C	D	E	F	G
t	1	1	1	1	1	1	1
t'	1	1	0	0	1	0	0




► Soit $\Sigma = \{AB \rightarrow D, CD \rightarrow F, DE \rightarrow G\}$. On cherche ABE^{Σ} .

►

Trace sur un exemple

	A	B	C	D	E	F	G
t	1	1	1	1	1	1	1
t'	1	1	0	0	1	0	0




► Soit $\Sigma = \{AB \rightarrow D, CD \rightarrow F, DE \rightarrow G\}$. On cherche ABE^{Σ} .

►

Trace sur un exemple

	A	B	C	D	E	F	G
t	1	1	1	1	1	1	1
t'	1	1	0	0	1	0	0




► Soit $\Sigma = \{AB \rightarrow D, CD \rightarrow F, DE \rightarrow G\}$. On cherche ABE^{Σ} .

►

Trace sur un exemple

	A	B	C	D	E	F	G
t	1	1	1	0	1	1	1
t'	1	1	0	0	1	0	0




► Soit $\Sigma = \{AB \rightarrow D, CD \rightarrow F, DE \rightarrow G\}$. On cherche ABE^{Σ} .

►

Trace sur un exemple

	A	B	C	D	E	F	G
t	1	1	1	0	1	1	1
t'	1	1	0	0	1	0	0




► Soit $\Sigma = \{AB \rightarrow D, CD \rightarrow F, DE \rightarrow G\}$. On cherche ABE^{Σ} .

►

Trace sur un exemple

	<i>A</i>	<i>B</i>	<i>C</i>	<i>D</i>	<i>E</i>	<i>F</i>	<i>G</i>
<i>t</i>	1	1	1	0	1	1	0
<i>t'</i>	1	1	0	0	1	0	0




► Soit $\Sigma = \{AB \rightarrow D, CD \rightarrow F, DE \rightarrow G\}$. On cherche ABE^{Σ} .

►

Trace sur un exemple

	A	B	C	D	E	F	G
t	1	1	1	0	1	1	0
t'	1	1	0	0	1	0	0




► Soit $\Sigma = \{AB \rightarrow D, CD \rightarrow F, DE \rightarrow G\}$. On cherche ABE^{Σ} .

►

Trace sur un exemple

	A	B	C	D	E	F	G
t	1	1	1	0	1	1	0
t'	1	1	0	0	1	0	0



- ▶ Soit $\Sigma = \{AB \rightarrow D, CD \rightarrow F, DE \rightarrow G\}$. On cherche ABE^{Σ} .
- ▶ On obtient $ABE^{\Sigma} = ABDEG$.

Pour finir

- ▶ Soit $R = \{A, B, C, D, E\}$ et $\Sigma = \{AB \rightarrow C, AC \rightarrow D, BC \rightarrow E\}$:
 1. Construire une relation d'Armstrong r pour Σ ,
 2. Corriger la relation r pour que $r \models \Sigma \cup \{A \rightarrow E, B \rightarrow D\}$
 3. **Bonus** : remplir r avec des données « réalistes » (films, livres, types de pantoufles, pizzas, ...)