

DATA BASES DATA MINING

Functional dependencies exercise sheet

We recall the following inference rules, where reflexivity, augmentation and transitivity constitute the so called Armstrong's system.

$$\frac{Y \subseteq X}{X \rightarrow Y} \sigma_R \text{ (reflexivity)} \qquad \frac{X \rightarrow Y \quad X \rightarrow Z}{X \rightarrow YZ} \sigma_C \text{ (composition)}$$

$$\frac{X \rightarrow Y}{WX \rightarrow WY} \sigma_A \text{ (augmentation)} \qquad \frac{X \rightarrow YZ}{X \rightarrow Y} \sigma_D \text{ (decomposition)}$$

$$\frac{X \rightarrow Y \quad Y \rightarrow Z}{X \rightarrow Z} \sigma_T \text{ (transitivity)} \qquad \frac{X \rightarrow Y \quad WY \rightarrow Z}{WX \rightarrow Z} \sigma_P \text{ (pseudo-transitivity)}$$

A proof of $X \rightarrow Y$ from Σ written $\Sigma \vdash X \rightarrow Y$ is a *sequence* $\langle f_0, \dots, f_p \rangle$ of FDs s.t. $f_p = X \rightarrow Y$ and $\forall i \in [0..p]$ either $f_i \in \Sigma$, or f_i is the *conclusion* of a rule from the Armstrong's system of which all its *antecedents* $f_0 \dots f_p$ appear before f_i in the sequence.

Exercise 1 : Proof of Functional Dependencies (FD)

Let Σ be the following set of FDs:

$$\begin{array}{ll} BC \rightarrow A & D \rightarrow BE \\ AC \rightarrow B & B \rightarrow DE \\ AE \rightarrow C & C \rightarrow E \end{array}$$

1. Prove using Armstrong's system that the following dependencies are entailed by Σ

1. $AD \rightarrow C$
2. $AB \rightarrow C$
3. $AE \rightarrow BD$
4. $AC \rightarrow D$
5. $CD \rightarrow A$

Exercise 2 : Inference rules for FDs

1. Is the following inference rule correct? If true, prove it, otherwise, exhibit a counter-example.

$$\frac{XW \rightarrow Y \quad XY \rightarrow Z}{X \rightarrow (Z \setminus W)}$$

2. Show that any proof $F \vdash X \rightarrow Y$ using the σ_P rule can be transformed into a proof that uses solely σ_A et σ_T .
3. Show that any proof $F \vdash X \rightarrow Y$ using the σ_R , σ_A and σ_T rules can be transformed into a proof that uses solely σ_R et σ_P .
4. Conclude that the set of rules $\{\sigma_R, \sigma_P\}$ is sound and complete for the inference problem of FDs.

Exercise 3 : The syntactic closure is a closure

The *syntactic closure* of X w.r.t. Σ is defined as $X^* = \{A \mid \Sigma \vdash X \rightarrow A\}$. In the usual (algebraic) sense a *closure* is a mapping $\phi : \wp(E) \rightarrow \wp(E)$ ¹ that satisfies the three following properties:

Extensive $X \subseteq \phi(X)$

Increasing $X \subseteq Y \Rightarrow \phi(X) \subseteq \phi(Y)$

Idempotent $\phi(\phi(X)) = \phi(X)$

1. Show that X^* is a closure in the algebraic sense using the Armstrong's system. For idempotency, you may prove first that $\Sigma \vdash X \rightarrow X^*$.
2. Show that for all set of attributes Y , if $X \subseteq Y \subseteq X^*$ then $Y^* = X^*$
3. Use the previous property to compute the *set of closed sets* $Cl(\Sigma) = \{X^* \mid X \subseteq R\}$ for Σ as defined in exercise 1.

Exercise 4 : Functional dependencies and propositional logic ([1])

The goal of this exercise is to relate functional dependencies and (classical) propositional logic, to highlight the point that the syntactic resemblance between a FD and logical implication is not a sheer one.

Let \mathcal{P} be an infinite enumerable set of propositional variables and let Σ be a set of FD over \mathbf{R} . For each attribute $A \in \mathbf{R}$ we associate a corresponding *propositional variable* $\underline{A} \in \mathcal{P}$. This mapping is extended to FD: for each FD $A_1 \dots A_p \rightarrow B_1 \dots B_q \in \Sigma$ we associate the propositional formula $\underline{A}_1 \wedge \dots \wedge \underline{A}_p \Rightarrow \underline{B}_1 \wedge \dots \wedge \underline{B}_q$ with variables in \mathcal{P} . Finally, we write $\underline{\Sigma}$ for the set of propositional formulas associated to Σ . Let $\alpha = A_1 \dots A_p \rightarrow B_1 \dots B_q$ be a FD, we want to show that the following are equivalent:

$$\Sigma \models \alpha \tag{1}$$

$$\Sigma \models_2 \alpha \tag{2}$$

$$\underline{\Sigma} \models_{\mathcal{P}} \underline{\alpha} \tag{3}$$

We write $\Sigma \models \alpha$ for the usual logical entailment between a set of FD Σ and a single FD α . We write $\Sigma \models_2 \alpha$ for the logical entailment restricted to the case where *relations have at most two tuples*. In other words, $\Sigma \models_2 \alpha$ is defined as $\forall r. (|r| = 2 \wedge r \models \Sigma) \Rightarrow r \models \alpha$. Finally, $\underline{\Sigma} \models_{\mathcal{P}} \underline{\alpha}$ is the classical propositional logical entailment, i.e., for all assignment of propositional variables $\nu : \mathcal{P} \rightarrow \{0, 1\}$ such that $\nu \models \underline{\Sigma}$ it is the case that $\nu \models \underline{\alpha}$ as well.

Lemma 1. *Let $\nu : \mathcal{P} \rightarrow \{0, 1\}$ be an assignment of propositional variables, and let $r = \{t_1, t_2\}$ be the instance with two tuples t_1 and t_2 such that $t_1[A] = 1$ and $t_2[A] = \nu(\underline{A})$ for all $A \in \mathbf{R}$. Let $\alpha = A_1 \dots A_p \rightarrow B_1 \dots B_q$ be a FD. Then $\nu \models_{\mathcal{P}} \underline{\alpha}$ if and only if $r \models \alpha$.*

1. Show that proposition (1) is equivalent to proposition (2). For the (2) \Rightarrow (1) direction, use proof by contradiction (show that $\Sigma \models_2 \alpha$ and $\Sigma \not\models \alpha$ is inconsistent).
2. Show lemma 1 by constructing a two tuples instance "à la Armstrong" from ν and vice-versa.
3. Show that proposition (3) is equivalent to proposition (2) using lemma 1. Use proof by contradiction for each direction.
4. Conclude the main theorem.

References

- [1] R. Fagin. Functional dependencies in a relational database and propositional logic. *IBM J. Res. Dev.*, 21(6):534–544, Nov. 1977.

¹ $\wp(E)$ is the set of all subsets of E , formally $\wp(E) = \{X \mid X \subseteq E\}$

Corrections

Solution de l'exercice 1

$$1. \quad 1. \quad \frac{\frac{D \rightarrow BE}{AD \rightarrow ABE} \text{ aug.} \quad \frac{AE \subseteq ABE}{ABE \rightarrow AE} \text{ refl.}}{AD \rightarrow AE} \text{ trans.} \quad \frac{AD \rightarrow AE \quad AE \rightarrow C}{AD \rightarrow C} \text{ trans.}$$

2. $AB \rightarrow C$

$B \rightarrow DE$ donc $AB \rightarrow ADE$ par augmentation

$AB \rightarrow AE$ par décomposition

$AB \rightarrow C$ puisque $AE \rightarrow C$ par transitivité

3. $AE \rightarrow BD$

$AE \rightarrow C$ donc $AE \rightarrow AC$ par augmentation

$AC \rightarrow B$ donc $AE \rightarrow B$ par transitivité

$B \rightarrow DE$ donc $B \rightarrow D$ par décomposition

On en déduit $AE \rightarrow D$ par transitivité

Par composition, on a $AE \rightarrow BD$.

4. $AC \rightarrow D$

$B \rightarrow DE$ donc $B \rightarrow D$ par décomposition

Or $AC \rightarrow B$ donc $AC \rightarrow D$ par transitivité

$$5. \quad \frac{\frac{D \rightarrow BE}{D \rightarrow B} \text{ decomp.} \quad \frac{CD \rightarrow BC}{BC \rightarrow A} \text{ aug.}}{CD \rightarrow A} \text{ trans.}$$

Solution de l'exercice 2

1. Non, on exhibe un contre-exemple avec l'instance suivante qui satisfait $XW \rightarrow Y$ et $XY \rightarrow Z$ mais pas $X \rightarrow (Z \setminus W)$:

W	X	Y	Z
w_0	x_0	y_0	z_0
w_1	x_0	y_1	z_1

2. Il s'agit de montrer que l'on peut prouver $WX \rightarrow Z$ à partir de $X \rightarrow Y$ et $WY \rightarrow Z$ en utilisant uniquement σ_A et σ_T :

$$\frac{\frac{X \rightarrow Y}{WX \rightarrow WY} \sigma_A \quad WY \rightarrow Z}{WX \rightarrow Z} \sigma_T$$

3. Comme σ_R appartient aux deux ensembles, il suffit de montrer la transitivité et l'augmentation à l'aide de la réflexivité et la pseudo-transitivité seulement. La transitivité est en fait un cas dégénéré de la pseudo-transitivité avec $W = \emptyset$:

$$\frac{X \rightarrow Y \quad Y \rightarrow Z}{X \rightarrow Z} \sigma_P$$

Pour l'augmentation s'obtient en posant $Z = WY$ dans la règle de pseudo-transitivité :

$$\frac{X \rightarrow Y \quad \frac{WY \subseteq WY}{WY \rightarrow WY} \sigma_R}{WX \rightarrow WY} \sigma_P$$

4. L'antépénultième question montre que le système $\{\sigma_R, \sigma_P\}$ est correct. D'autre part, on sait que le système d'Armstrong $\{\sigma_R, \sigma_A, \sigma_T\}$ est complet, la question précédente montre que on peut transformer toutes les preuves de ce système par des preuves ne faisant intervenir que $\{\sigma_R, \sigma_P\}$ ce qui montre sa complétude.

Solution de l'exercice 3

1. **Extensive** Soit $A \in X$, par l'axiome de réflexivité on a $\vdash X \rightarrow A$ et donc $A \in \{A \mid \Sigma \vdash X \rightarrow A\}$.

Croissante Soit $X \subseteq Y$, il faut montrer que $X^* \subseteq Y^*$. Considérons $A \in X^*$, par définition, il existe une preuve de $\Sigma \vdash X \rightarrow A$. Comme $X \subseteq Y$, par l'axiome de réflexivité on a $\vdash Y \rightarrow X$. Par transitivité on a une preuve de $\Sigma \vdash Y \rightarrow A$, c'est-à-dire $A \in Y^*$.

Idempotente On montre la double inclusion. Pour la première direction, on a $X \subseteq X^*$ et par monotonie $X^* \subseteq (X^*)^*$. Pour la seconde direction, il faut prouver que $(X^*)^* \subseteq X^*$. On prouve d'abord que $\Sigma \vdash X \rightarrow X^*$. Supposons sans perte de généralités que $X^* = A_1 \dots A_n$, pour tout indice $1 \leq i \leq n$, par définition, si $A_i \in X^*$ alors on a une preuve que $\Sigma \vdash X \rightarrow A_i$. Or on peut concaténer toutes ces preuves puis répéter la règle de composition² $\{X \rightarrow Y, X \rightarrow Z\} \vdash X \rightarrow YZ$ pour obtenir une preuve de $\Sigma \vdash X \rightarrow X^*$. Considérons $A \in (X^*)^*$, par définition, on a une preuve $\Sigma \vdash X^* \rightarrow A$ (notez le X^*), comme on a prouvé que $\Sigma \vdash X \rightarrow X^*$, on peut conclure par transitivité.

2. Tout d'abord, on sait que $X^* = X^+$ et on raisonnera sur X^+ . D'une part, par hypothèse $X \subseteq Y$ et donc par monotonie on a $X^+ \subseteq Y^+$. D'autre part, par hypothèse, $Y \subseteq X^+$ et donc par monotonie puis par idempotence on a $Y^+ \subseteq (X^+)^+ = X^+$. On a donc $X^+ \subseteq Y^+ \subseteq X^+$ et on conclut par antisymétrie de la relation d'inclusion.

3. On procède par niveaux : calculer les fermetures de tous les singletons, puis des couples d'attributs, puis des ensembles de trois attributs etc. Au total, il y a $2^5 = 32$ sous-ensembles dont il faudrait calculer la fermeture. On rappelle que le nombre de combinaisons de k parmi n est $\binom{n}{k} = \frac{n!}{k!(n-k)!}$

niveau 1	
$A^+ = A$	
$B^+ = BDE$	
$C^+ = CE$	
$D^+ = BDE$	
$E^+ = E$	
niveau 2	
$AB^+ = R$	
$AC^+ = R$	
$AD^+ = R$	
$AE^+ = R$	
$BC^+ = R$	
$BD^+ = BDE$	(1)
$BE^+ = BDE$	(2)
$CD^+ = R$	
$CE^+ = CE$	(3)

Pour (1) et (2), comme $B \subseteq BD \subseteq B^+ = BDE$, on déduit que $BD^+ = BDE$. De la même façon pour (3), en remarquant que $C \subseteq CE \subseteq C^+ = CE$, on déduit $CE^+ = CE$. Pour le niveau 3, on doit énumérer les $\binom{5}{2} = 10$ ensembles de taille 3, mais en remarquant que $AB^+ = AC^+ = AD^+ = AE^+$ on peut éliminer tous ceux qui contiennent A . Il en reste donc $\binom{4}{3} = 4$, à savoir $\{BCD, BDE, BCE, CDE\}$

niveau 3	
$BCD^+ = R$	(4)
$BDE^+ = BDE$	(5)
$BCE^+ = R$	(6)
$CDE^+ = R$	(7)

Pour (4) et (7), on remarque que BCD^+ et CDE^+ contiennent CD et donc leur fermeture est R . Pour (5), on le connaît déjà, et enfin pour (6), on utilise le fait que $BC^+ = R$. On a terminé, car il ne reste que $BCDE$ à tester (le seul sous-ensemble de taille 4 qui ne contienne pas A) et on sait que $BCDE^+ = R$. En conclusion, on a :

$$CI(\Sigma) = \{A, E, CE, BDE, R\}$$

²cette dernière étant simplement une combinaison d'augmentation et de transitivité.

Solution de l'exercice 4

1. Le sens (1) \Rightarrow (2) est clair car si $\Sigma \models \alpha$ pour toute relation r , alors c'est aussi vrai pour le cas limité à $|r| = 2$. Pour la réciproque (2) \Rightarrow (1), supposons le contraire, c'est-à-dire $\Sigma \models_2 \alpha$ et $\Sigma \not\models \alpha$, pour aboutir à une contradiction. Si $\Sigma \not\models \alpha$, alors il existe une relation r (de taille arbitraire) telle que $r \models \Sigma$ et $r \not\models \alpha$. Cela signifie qu'ils existent (au moins) deux tuples $t_1, t_2 \in r$ tels que $t_1[A_1 \dots A_p] = t_2[A_1 \dots A_p]$ et $t_1[B_1 \dots B_q] \neq t_2[B_1 \dots B_q]$. Il suffit donc de considérer la relation $r' = \{t_1, t_2\}$ qui a exactement deux tuples : elle vérifie Σ par hypothèse mais on vient de montrer qu'elle viole α , contradiction avec $\Sigma \models_2 \alpha$.
2. Pour la direction *si*. Supposons $r \models \alpha$, deux cas sont possibles :
 1. α est trivialement satisfaite car $t_1[A_i] \neq t_2[A_i]$ pour un certain i . Dès lors $\nu \not\models A_1 \wedge \dots \wedge A_p$ car $\nu(A_i) = 0$ et ainsi $\nu \models A_1 \wedge \dots \wedge A_p \Rightarrow B_1 \wedge \dots \wedge B_q$ par inspection de la table de vérité de \Rightarrow .
 2. α est satisfaite car $t_1[A_i] = t_2[A_i]$ pour tout i et de même $t_1[B_j] = t_2[B_j]$. On a donc $\nu \models A_1 \wedge \dots \wedge A_p$ et également $\nu \models B_1 \wedge \dots \wedge B_q$. On conclut encore par inspection de la table de vérité de \Rightarrow .

Pour la direction *seulement si*, on suppose que $\nu \models_P \underline{\alpha}$ et on considère encore les deux cas :

 1. soit $\nu \models_P \underline{\alpha}$ par vacuité car $\nu(A_i) = 0$ pour un certain i et donc dans ce cas α est trivialement satisfaite car $t_1[A_i] \neq t_2[A_i]$,
 2. soit on a $\nu(A_i) = 1$ pour tout i et aussi $\nu(B_j) = 1$ pour chaque j car $\nu \models_P \underline{\alpha}$. Dans ce cas aussi α est satisfaite car $\{t_1, t_2\}$ est le seul couple de tuple à considérer pour vérifier $r \models \alpha$.
3. Pour le sens (3) \Rightarrow (2) on procède par l'absurde. On suppose donc $\Sigma \models_2 \alpha$ et $\underline{\Sigma} \not\models_P \underline{\alpha}$. Il existe donc une valuation ν telle que $\nu \models_P \underline{\Sigma}$ et $\nu \not\models_P \underline{\alpha}$. Par inspection de la table de vérité de \Rightarrow , cela signifie que $\nu(A_i) = 1$ pour tout i mais qu'il existe (au moins) un index j tel que $\nu(B_j) = 0$. A partir de cette valuation, construisons alors une relation $r = \{t_1, t_2\}$ telle que décrit dans le lemme 1. D'après le lemme on a $r \not\models \alpha$ et $r \models \Sigma$, contradiction.
 Pour le sens (2) \Rightarrow (3), on a procédé de façon similaire en supposant $\underline{\Sigma} \models_P \underline{\alpha}$ et $\Sigma \not\models_2 \alpha$. On a donc au moins une relation à deux tuples $r = \{t_1, t_2\}$ qui vérifie Σ mais pas α . On construit alors la valuation ν telle que $\nu(A) = 1$ si et seulement si $t_1[A] = t_2[A]$. On est dans le cas d'application du lemme 1 et d'après celui-ci on déduit que $\nu \not\models \underline{\alpha}$ et $\nu \models \underline{\Sigma}$, une contradiction.
4. D'après la question 1 on a (1) \equiv (3), d'après la question 3 on a aussi (2) \equiv (3), les trois propositions sont donc équivalentes.