

# Explications analogiques

Henri Prade   Gilles Richard

**IRIT**

CNRS & Université Paul Sabatier

Toulouse

présenté à l'Atelier "Explain'AI" de la conférence EGC, Blois, 25 Jan. 2022

## *L'explication est une thématique ancienne en IA*

- Une “intelligence”, fut-elle artificielle, doit pouvoir *expliquer ses conclusions*
- Déjà, le succès des *systèmes experts*, à base de *règles*, il y a un peu plus de 30 ans avait conduit à des travaux pour développer des systèmes capables d'expliquer leurs conclusions
- Malgré une idée encore répandue, pas de divorce entre *logique* et *réseaux de neurones*

## *Explications et logique*

- Explications (en termes de sensibilité) dans des systèmes de règles *incertaines* (dans le cadre de la *théorie des possibilités*) sous forme de cascades de produits min-max de matrices (Farreny et Prade, 1989-1990)
- repris, *généralisé*, mis sous forme de **réseaux de neurones**, et exploité à des fins d'explications (Baaaj, 2021)
- Une analyse logique de *classifieurs* en termes d'explications *abductives* (réponse à une question de type "pourquoi ?") ou *contrastives* (type "pourquoi pas ?") (Marques-Silva et al., 2021)

## *Explications et logique*

- Explications (en termes de sensibilité) dans des systèmes de règles *incertaines* (dans le cadre de la *théorie des possibilités*) sous forme de cascades de produits min-max de matrices (Farreny et Prade, 1989-1990)
- repris, *généralisé*, mis sous forme de **réseaux de neurones**, et exploité à des fins d'explications (Baaaj, 2021)
- Une analyse logique de *classifieurs* en termes d'explications *abductives* (réponse à une question de type “pourquoi ?”) ou *contrastives* (type “pourquoi pas ?”) (Marques-Silva et al., 2021)

## Explication abductive

- $\mathcal{A}$  un ensemble de  $n$  attributs  $i = 1, \dots, n$   
 $x_i$  une valeur de l'attribut  $i$   
 $v_i$  une constante de  $\mathcal{D}_i$ , domaine de l'attribut  $i$   
 $\mathcal{D} = \mathcal{D}_1 \times \dots \times \mathcal{D}_n$   
 et  $cl$  une **fonction de classification**
- Etant donné  $cl(v) = c_0$  pour  $v = (v_1, \dots, v_n)$ , une **explication abductive** (par implicant premier) est constituée par n'importe quel sous-ensemble **minimal**  $\mathcal{X} \subseteq \mathcal{A}$  tel que  

$$\forall x \in \mathcal{D}. [\bigwedge_{i \in \mathcal{X}} (x_i = v_i)] \rightarrow (cl(x) = c_0)$$
- Cela suffit de fixer les valeurs  $x_i$  des attributs de  $\mathcal{X}$  à  $v_i$  pour assurer que  $cl(x) = c_0$

## *Explication contrastive*

- Etant donné  $cl(v) = c_0$ , une **explication contrastive** est constituée par n'importe quel sous-ensemble **minimal**  $\mathcal{Y} \subseteq \mathcal{A}$  tel que

$$\exists x \in \mathcal{D}. \left[ \bigwedge_{j \in \mathcal{A} \setminus \mathcal{Y}} (x_j = v_j) \right] \wedge (cl(x) \neq c_0)$$

- On peut trouver un  $x$ , en dehors de  $c_0$ , qui coïncide avec  $v$  sur un sous-ensemble **maximal** d'attributs, i.e., on peut effectuer un changement minimal sur  $v$  afin que  $x$  ne soit plus dans  $c_0$
- Cela correspond à une réponse à la question “Pourquoi pas  $cl(v) \neq c_0$ ?”, i.e., on identifie les attributs dont la valeur doit être changée pour cela

## Modélisation booléenne

- **analogie** : mise en parallèle de 2 situations  
établir une correspondance entre les éléments  
des 2 situations et les relations qui les lient
- **proportion analogique** : “ $a$  est à  $b$  ce que  $c$  est à  $d$ ”  
“le veau est à la vache

- $a : b :: c : d =$  ce que le poulain est à la jument”  
 $((a \wedge \neg b) \equiv (c \wedge \neg d)) \wedge ((\neg a \wedge b) \equiv (\neg c \wedge d))$

$$0 : 0 :: 0 : 0$$

$$1 : 1 :: 1 : 1$$

$$0 : 1 :: 0 : 1$$

- $1 : 0 :: 1 : 0$

$$0 : 0 :: 1 : 1$$

$$1 : 1 :: 0 : 0$$

## Exemple et propriétés

- items  $a, b, c, d$  : vecteurs de valeurs de  $n$  attributs  
 $a : b :: c : d$  ssi  $\forall i \in \{1, \dots, n\}, a_i : b_i :: c_i : d_i$

	mammifère	carnivore	bovidé	équidé	jeune	adulte
veau	1	0	1	0	1	0
vache	1	0	1	0	0	1
poulain	1	0	0	1	1	0
jument	1	0	0	1	0	1

- $a : b :: c : d \Rightarrow a : c :: b : d$  permutation centrale
- $a : b :: c : d \Rightarrow c : d :: a : b$  symétrie
- $a : b :: c : d$  et  $c : d :: e : f \Rightarrow a : b :: e : f$  transitivité
- $a : b :: c : d \Rightarrow \neg a : \neg b :: \neg c : \neg d$  indépendance au codage

on peut recalculer  $d$  à partir de  $a, b, c$

## Exemple et propriétés

- items  $a, b, c, d$  : vecteurs de valeurs de  $n$  attributs  
 $a : b :: c : d$  ssi  $\forall i \in \{1, \dots, n\}, a_i : b_i :: c_i : d_i$

	mammifère	carnivore	bovidé	équidé	jeune	adulte
veau	1	0	1	0	1	0
vache	1	0	1	0	0	1
poulain	1	0	0	1	1	0
jument	1	0	0	1	0	1

- $a : b :: c : d \Rightarrow a : c :: b : d$  permutation centrale
- $a : b :: c : d \Rightarrow c : d :: a : b$  symétrie
- $a : b :: c : d$  et  $c : d :: e : f \Rightarrow a : b :: e : f$  transitivité
- $a : b :: c : d \Rightarrow \neg a : \neg b :: \neg c : \neg d$  indépendance au codage

on peut recalculer  $d$  à partir de  $a, b, c$

## Une lecture des données tournée vers l'explication

	$\mathcal{A}_1 \dots \mathcal{A}_{j-1}$	$\mathcal{A}_j \dots \mathcal{A}_{j-1}$	$\mathcal{A}_j \dots \mathcal{A}_{k-1}$	$\mathcal{A}_k \dots \mathcal{A}_{r-1}$	$\mathcal{A}_r \dots \mathcal{A}_{s-1}$	$\mathcal{A}_s \dots \mathcal{A}_n$	$\mathcal{C}$
<i>a</i>	1	0	1	0	1	0	<i>p</i>
<i>b</i>	1	0	1	0	0	1	<i>q</i>
<i>c</i>	1	0	0	1	1	0	<i>r</i>
<i>d</i>	1	0	0	1	0	1	<i>s</i>

- $p:q::r:s$  vrai ssi  $p=q$  et  $r=s$ , ou  $p=r$  et  $q=s$

- cas  $p=r$  et  $q=s$  ( $p \neq q$ ) Le basculement de valeur de  $\mathcal{C}$  de  $p$  à  $q$  entre  $a$  et  $b$  et entre  $c$  et  $d$  ne peut

être expliqué, au vu des attributs considérés que par

le changement de valeurs des attributs de  $\mathcal{A}_r$  à  $\mathcal{A}_n$

(qui est le même pour la paire  $(a, b)$  et la paire  $(c, d)$ )

- voir ces paires comme des instances d'une règle

exprimant que le changement sur les attributs de  $\mathcal{A}_r$  à  $\mathcal{A}_n$

détermine le changement sur  $\mathcal{C}$  quelque soit le contexte

## Une lecture des données tournée vers l'explication

	$\mathcal{A}_1 \dots \mathcal{A}_{j-1}$	$\mathcal{A}_j \dots \mathcal{A}_{j-1}$	$\mathcal{A}_j \dots \mathcal{A}_{k-1}$	$\mathcal{A}_k \dots \mathcal{A}_{r-1}$	$\mathcal{A}_r \dots \mathcal{A}_{s-1}$	$\mathcal{A}_s \dots \mathcal{A}_n$	$\mathcal{C}$
$a$	1	0	1	0	1	0	$p$
$b$	1	0	1	0	0	1	$q$
$c$	1	0	0	1	1	0	$r$
$d$	1	0	0	1	0	1	$s$

- $p:q::r:s$  vrai ssi  $p=q$  et  $r=s$ , ou  $p=r$  et  $q=s$
- cas  $p=r$  et  $q=s$  ( $p \neq q$ ) Le **basculement** de valeur de  $\mathcal{C}$  de  $p$  à  $q$  entre  $a$  et  $b$  et entre  $c$  et  $d$  ne peut être expliqué, au vu des attributs considérés que par le **changement** de valeurs des attributs de  $\mathcal{A}_r$  à  $\mathcal{A}_n$  (qui est le même pour la paire  $(a, b)$  et la paire  $(c, d)$ )

• voir ces paires comme des instances d'une règle

exprimant que le changement sur les attributs de  $\mathcal{A}_r$  à  $\mathcal{A}_n$

détermine le changement sur  $\mathcal{C}$  **quel que soit le contexte**

## Une lecture des données tournée vers l'explication

	$\mathcal{A}_1 \dots \mathcal{A}_{j-1}$	$\mathcal{A}_j \dots \mathcal{A}_{j-1}$	$\mathcal{A}_j \dots \mathcal{A}_{k-1}$	$\mathcal{A}_k \dots \mathcal{A}_{r-1}$	$\mathcal{A}_r \dots \mathcal{A}_{s-1}$	$\mathcal{A}_s \dots \mathcal{A}_n$	$\mathcal{C}$
$a$	1	0	1	0	1	0	$p$
$b$	1	0	1	0	0	1	$q$
$c$	1	0	0	1	1	0	$r$
$d$	1	0	0	1	0	1	$s$

- $p:q::r:s$  vrai ssi  $p=q$  et  $r=s$ , ou  $p=r$  et  $q=s$

- cas  $p=r$  et  $q=s$  ( $p \neq q$ ) Le **bascullement** de valeur de  $\mathcal{C}$  de  $p$  à  $q$  entre  $a$  et  $b$  et entre  $c$  et  $d$  ne peut

être expliqué, au vu des attributs considérés que par

le **changement** de valeurs des attributs de  $\mathcal{A}_r$  à  $\mathcal{A}_n$

(qui est le même pour la paire  $(a, b)$  et la paire  $(c, d)$ )

- voir ces **paires** comme des instances d'une **règle**

exprimant que le changement sur les attributs de  $\mathcal{A}_r$  à  $\mathcal{A}_n$

détermine le changement sur  $\mathcal{C}$  **quelque soit le contexte**

## Petite illustration

cas	situation	contre – indication (c. i)	decision	option 1	option 2
a	$sit_1$	<i>oui</i>	$\delta$	0	0
b	$sit_1$	<i>non</i>	$\delta$	1	0
c	$sit_2$	<i>oui</i>	$\delta$	0	1
d	$sit_2$	<i>non</i>	$\delta$	1	1

- décision : peut-on servir un café avec ou sans sucre (option 1), avec ou sans lait (option 2) à une personne dans un établissement médicalisé

Que peut-on faire en  $sit_2$  sans c. i. ?

- question** “pourquoi du lait et du sucre pour d?”

*réponse* (le lait) “parce qu’on est en  $sit_2$  (et pas en  $sit_1$ )”

“parce qu’il n’y pas de c. i.” pour le sucre

**question** “pourquoi pas de lait pour b?”,

*réponse* “parce que l’on est en  $sit_1$  (et pas en

## Petite illustration

cas	situation	contre – indication (c. i.)	decision	option 1	option 2
a	$sit_1$	<i>oui</i>	$\delta$	0	0
b	$sit_1$	<i>non</i>	$\delta$	1	0
c	$sit_2$	<i>oui</i>	$\delta$	0	1
d	$sit_2$	<i>non</i>	$\delta$	1	1

- décision : peut-on servir un café avec ou sans sucre (option 1), avec ou sans lait (option 2) à une personne dans un établissement médicalisé

Que peut-on faire en  $sit_2$  sans c. i. ?

- question** “pourquoi du lait et du sucre pour d?”

*réponse* (le lait) “parce qu’on est en  $sit_2$  (et pas en  $sit_1$ )”  
 “parce qu’il n’y pas de c. i.” pour le sucre

*question* “pourquoi pas de lait pour b?”,

*réponse* “parce que l’on est en  $sit_1$  (et pas en

## Petite illustration

cas	situation	contre – indication (c. i)	decision	option 1	option 2
a	$sit_1$	<i>oui</i>	$\delta$	0	0
b	$sit_1$	<i>non</i>	$\delta$	1	0
c	$sit_2$	<i>oui</i>	$\delta$	0	1
d	$sit_2$	<i>non</i>	$\delta$	1	1

- décision : peut-on servir un café avec ou sans sucre (option 1), avec ou sans lait (option 2) à une personne dans un établissement médicalisé

Que peut-on faire en  $sit_2$  sans c. i. ?

- question** “pourquoi du lait et du sucre pour d?”

*réponse* (le lait) “parce qu’on est en  $sit_2$  (et pas en  $sit_1$ )”

“parce qu’il n’y pas de c. i.” pour le sucre

**question** “pourquoi pas de lait pour b?”,

*réponse* “parce que l’on est en  $sit_1$  (et pas en

## Analogie et explication contrastive

<i>cas</i>	<i>contexte</i>	<i>changement</i>	<i>cl</i>
<i>a</i>	<i>sit<sub>1</sub></i>	<i>oui</i>	<i>p</i>
<i>b</i>	<i>sit<sub>1</sub></i>	<i>non</i>	<i>q</i>
<i>c</i>	<i>sit<sub>2</sub></i>	<i>oui</i>	<i>p</i>
<i>d</i>	<i>sit<sub>2</sub></i>	<i>non</i>	<i>q</i>

*Table:* Situation schématique de l'explication analogique

- la réponse à la question “pourquoi *d* n'est pas en classe *p*?” est dans les valeurs prises par *d* pour les attributs de *change*. Quand *c* est un proche voisin de *d*, le nombre d'attributs dans *change* est **petit**. On est proche d'une explication **contrastive** :  

$$\exists x = c \in \mathcal{S}. [\bigwedge_{j \in A \setminus \text{change}} (x_j = c_j = d_j)] \wedge (cl(x) \neq q)$$
- explication contrastive  

$$\exists x \in \mathcal{D}. [Desaccord(x, v) = \mathcal{Y} \wedge (cl(x) \neq c_0)]$$

## Analogie et explication abductive

- L'explication est ici plus riche, on connaît au moins une autre paire (ici  $(a, b)$ ), correspondant à un autre *contexte* où le même changement de valeur d'attributs conduit au même changement de classe, ce qui suggère la possibilité des **règles**  $\forall sit$ ,

$$(contexte = sit) \wedge (chang. = oui) \rightarrow cl((sit, non)) = p$$

$$(contexte = sit) \wedge (chang. = non) \rightarrow cl((sit, non)) = q$$

la règle permet une lecture de la Table avec un parfum d'explication **abductive**, qui dit pourquoi the item is in class  $p$  (or in class  $q$ ).

explicat. abductive  $\forall x. [(Acc.(x, v) = \mathcal{X}) \rightarrow (cl(x) = c_0)]$

- MAIS **exception** si  $\exists (a', b')$  t. q.  $a' = (sit', oui)$ ,  
 $b' = (sit', non)$  with  $cl(a') = cl(b') = p$

## *Pour résumer*

- les proportions analogiques ont un important potentiel explicatif **à partir de données**
- on peut répondre à des questions de types “*pourquoi*” et “*pourquoi pas*”.
- approche apparentée, à celle du système LORE (Local Rule-Based explanations) (Guidotti et al. 2018)
- rôle des exemples “*adverses*” dans l’explication
- **une proportion analogique a une valeur explicative**  
“*Star Wars (1977) est à Raiders of the Lost Ark (1981) comme Return of the Jedi (1983) est à Indiana Jones and the Last Crusade (1989)*”

## *Pour résumer*

- les proportions analogiques ont un important potentiel explicatif **à partir de données**
- on peut répondre à des questions de types “*pourquoi*” et “*pourquoi pas*”.
- approche apparentée, à celle du système LORE (Local Rule-Based explanations) (Guidotti et al. 2018)
- rôle des exemples “*adverses*” dans l’explication
- **une proportion analogique a une valeur explicative** “*Star Wars (1977) est à Raiders of the Lost Ark (1981) comme Return of the Jedi (1983) est à Indiana Jones and the Last Crusade (1989)*”

## *Lien avec l'argumentation*

- **discutant  $d$**  : situation  $S_2$  est comme situation  $S_1$   
ce qui s'est passé dans  $S_1$  arrivera aussi dans  $S_2$   
Le **discutant adverse  $d'$**  :

il y a une caractéristique (importante) où ils *diffèrent*  
ce qui s'est passé dans  $S_1$  n'arrivera pas en  $S_2$

- $d$  peut produire une autre paire de situations  
( $S_3, S_4$ ) où *la même différence* peut être observée  
***sans affecter la conclusion*** de  $d$  pour  $S_2$ .
- $d'$  peut contre-argumenter s'il connaît une autre  
paire de situations ( $S'_3, S'_4$ ) où la même différence  
conduit à une *conclusion différente*
- **analysable avec des proportions analogiques**

## Remarques de conclusion - 1

- Hüllermeier (2020) : usage explicatif des proportions analogiques en apprentissage
- classification et apprentissage de préférences
- inférence analogique conclut de  $a : b :: c : d$  et de “ $a$  est préféré à  $b$ ”, que “ $c$  est préféré à  $d$ ”  
L'explication analogique *s'appliquerait aussi*.
- plusieurs scénarios : 1) expliquer une prédiction concernant / la valeur d'un attribut de  $d$ , sur la base de triplets  $a, b, c$  de l'ensemble des données  
2) extraire des proportions analogiques d'un ensemble de données

## Remarques de conclusion - 1

- Hüllermeier (2020) : usage explicatif des proportions analogiques en apprentissage
- classification et apprentissage de préférences
- inférence analogique conclut de  $a : b :: c : d$  et de “ $a$  est préféré à  $b$ ”, que “ $c$  est préféré à  $d$ ”  
L'explication analogique *s'appliquerait aussi*.
- plusieurs scénarios : 1) expliquer une prédiction concernant / la valeur d'un attribut de  $d$ , sur la base de triplets  $a, b, c$  de l'ensemble des données  
2) extraire des proportions analogiques d'un ensemble de données

## Remarques de conclusion - 2

- intéressant de *précompiler* l'ensemble des données sous forme de **paires** en repérant où les items sont égaux et où et comment ils diffèrent  
**pour faciliter une analyse analogique des données**

commencer par déterminer les attributs **pertinents**  
*confiance, support* des règles associées aux paires  
vient d'être d'implémenté

- une 2nde sorte de PA où  $a$  et  $c$  d'une part et  $b$  et  $d$  d'autre part appartiennent à **2 univers différents**:  
"ce médicament est au rhume ce que l'aspirine est au mal de tête" (il est assez officieux et très cher)

## Remarques de conclusion - 2

- intéressant de *précompiler* l'ensemble des données sous forme de **paires** en repérant où les items sont égaux et où et comment ils diffèrent  
**pour faciliter une analyse analogique des données**

commencer par déterminer les attributs **pertinents**  
*confiance*, *support* des règles associées aux paires  
vient d'être d'implémenté

- une 2nde sorte de PA où  $a$  et  $c$  d'une part et  $b$  et  $d$  d'autre part appartiennent à **2 univers différents**:  
"ce médicament est au rhume ce que l'aspirine est au mal de tête" (il est assez officiellement recherché)

## Remarques de conclusion - 2

- intéressant de *précompiler* l'ensemble des données sous forme de **paires** en repérant où les items sont égaux et où et comment ils diffèrent  
**pour faciliter une analyse analogique des données**

commencer par déterminer les attributs **pertinents**  
*confiance*, *support* des règles associées aux paires  
vient d'être d'implémenté

- une 2nde sorte de PA où  $a$  et  $c$  d'une part et  $b$  et  $d$  d'autre part appartiennent à **2 univers différents**:  
"ce médicament est au rhume ce que l'aspirine est au mal de tête" (il est assez efficace et pas cher)