Intégration des biais de langage à l'algorithme générer-et-tester

Contributions à l'apprentissage disjonctif

Fabien Torre

Équipe Inférence et Apprentissage
Laboratoire de Recherche en Informatique
Université Paris-Sud, Orsay

28 janvier 2000

Apprentissage supervisé : grand-père

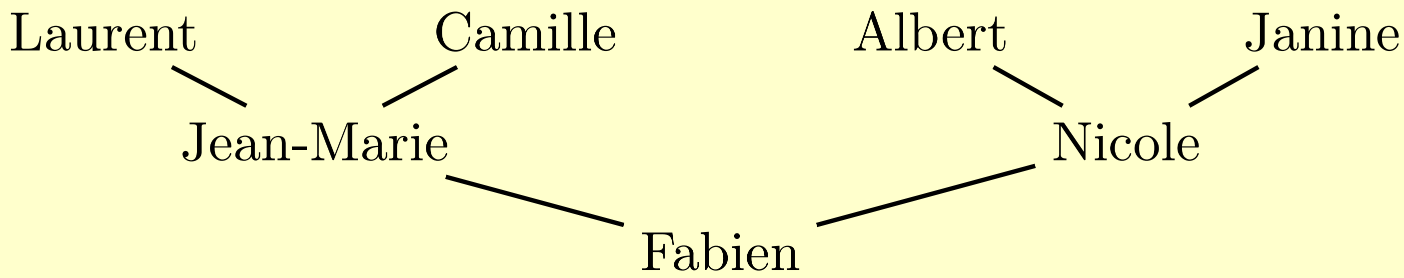

Entrées (Laurent,Fabien) et (Albert,Fabien) sont des exemples,
(Camille,Fabien) et (Janine,Fabien) des contre-exemples

Trouver une hypothèse couvrant les premiers, pas les seconds.

(A, B) appartient au concept grand-père
si A est le père de C *et* que C est un des deux parents de B.

(A, B) appartient au concept grand-père
si A est la mère de quelqu'un

Approche générer-et-tester

tout le monde est grand-père de tout le monde

- un grand-père est la mère de quelqu'un
  - un grand-père est la mère d'un parent de quelqu'un
- un grand-père est le père de quelqu'un
  - . . .
  - un grand-père est le père d'un parent de quelqu'un
- un grand-père est un parent de quelqu'un

But de la première partie : intégrer les connaissances a priori sur la solution dans le processus de recherche.

L'apprentissage disjonctif

- Apprentissage du concept *grand-père* sans disposer du concept de *parent* : pas d'hypothèse correcte et complète.
- Il faut recourir à une disjonction d'hypothèses :

  (A, B) appartient au concept grand-père
  si A est le père de C et que C est le père de B.

  ou

  (A, B) appartient au concept grand-père
  si A est le père de C et que C est la mère de B.
- Les exemples positifs appartiennent à différents sous-concepts.

But de la seconde partie : regrouper les exemples positifs en sous-concepts.

Plan de l'exposé

1. Apprentissage conjonctif en Programmation Logique Inductive
   (a) utilisation de biais
   (b) propriétés privées
   (c) relations naturelles
   (d) opérateurs idéaux pour ces relations naturelles
2. Apprentissage disjonctif en attribut-valeur
   (a) objectifs : optimiser la couverture des exemples positifs
   (b) algorithmes stochastiques du système GloBo
   (c) évaluation de la fiabilité

Conclusions et perspectives

Programmation Logique Inductive

[Muggleton and Buntine, 1988, Muggleton, 1991]

— Exemples et hypothèses sont des formules du premier ordre.
— Espaces de recherche infinis.
— Implication logique : indécidable. [Schmidt-Schauss, 1988]

Définition de la θ-subsomption [Plotkin, 1970]

C θ-subsume D s'il existe une substitution θ telle que $C\theta \subseteq D$.

— Équivalente à l'implication logique pour des clauses non récursives. [Gottlob, 1987]
— θ-subsomption : NP-complet. [Kapur and Narendran, 1986]

Biais de langage

[Utgoff and Mitchell, 1982, Utgoff, 1986]

- Les biais sont *nécessaires* à l'apprentissage. [Mitchell, 1980]
- Qualité des résultats et efficacité.
- Biais de langage en PLI : contraintes sur la syntaxe des hypothèses. [Nédellec et al., 1996]
  - champ réduit, connexion,
  - borne sur la taille, le nombre de variables, la profondeur, etc.
- Ces biais ne rendent pas la recherche plus efficace : l'élagage dynamique est généralement impossible par rapport à ces contraintes.

Élagage dynamique

Opérateur d'ajout, P_1 : couverture de e^+ et P_2 : rejet de e^-

Respect d'une relation de généralité pour permettre un élagage par rapport à la couverture des exemples. [Mitchell, 1982]

$$
\begin{tikzcd}
 & gp(A,B) \leftarrow \arrow[dl] \arrow[d] \arrow[dr] & \\
gp(A,B) \leftarrow m(A,C) & gp(A,B) \leftarrow p(A,C) \arrow[dl] \arrow[d] & gp(A,B) \leftarrow pa(C,B) \arrow[dl] \\
\cdots & gp(A,B) \leftarrow p(A,C), pa(C,B) &
\end{tikzcd}
$$

P_3 : champ réduit

Objectif : élaguer dynamiquement par rapport aux biais de langage.

Propriétés Privées

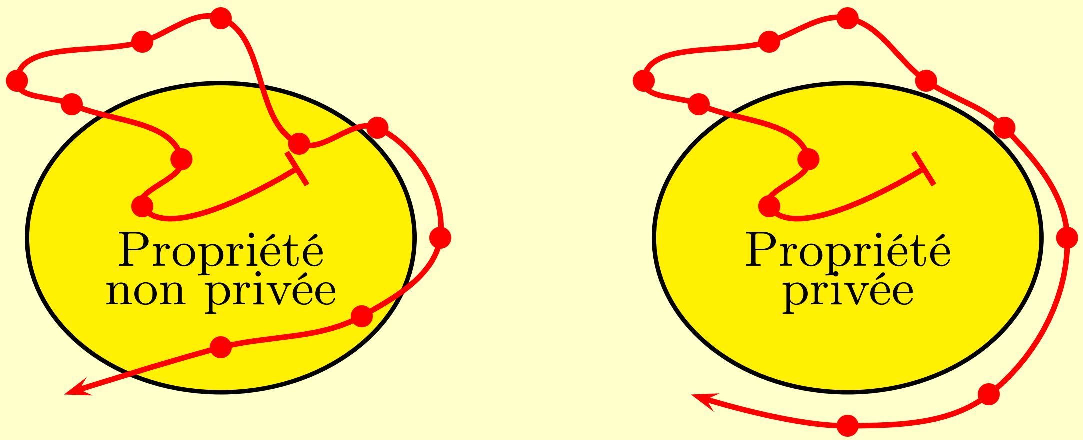

Définition d'une propriété privée

Une propriété P est dite *privée* par rapport à une relation $\mathcal{R}$ si et seulement si

$$H \, \mathcal{R} \, H' \wedge \overline{P(H)} \Rightarrow \overline{P(H')}$$

$\mathcal{R}$ = ajout, P = couverture de e^+ ou P = taille bornée.

Quelles sont les relations qui rendent une propriété privée ?

Relations naturelles

Relation naturelle d'une propriété P : une relation, la plus large possible, pour laquelle P est privée.

- La relation naturelle d'une propriété est unique : toute relation qui la rend privée est incluse dans sa relation naturelle.
- Deux hypothèses C et D sont en relation naturelle pour une propriété $f(H)\,\mathcal{R}\,k$ si et seulement si $f(C)\,\mathcal{R}\,f(D)$.

$$H \models e^+ \;\ldots\ldots\ldots\ldots\ldots\ldots\; C \models D$$

$$|H| \leq_{\mathbb{N}} 5 \;\ldots\ldots\ldots\ldots\; |C| \leq_{\mathbb{N}} |D|$$

- Recherche d'opérateurs dans les relations naturelles.

Opérateurs idéaux

Définition de l'idéalité [van der Laag and Nienhuys-Cheng, 1994]

Un opérateur $\mathcal{O}$ est *idéal* pour une relation de généralité $\succeq$ s'il est à la fois localement fini, strict et complet.

Localement fini : $\mathcal{O}(H)$ est calculable ;

Strict : $\mathcal{O}(H)$ ne contient aucune clause $\succeq$-équivalente à H ;

Complet : si H et H' sont comparables pour $\succeq$, $H \in \mathcal{O}^*(H')$ ou $H' \in \mathcal{O}^*(H)$.

Les opérateurs idéaux n'existent pas sous implication logique, ni sous θ-subsumption.

Un opérateur idéal pour $\succeq$ doit calculer les successeurs immédiats de chaque clause sous $\succeq$.

$$D_2 : q(X_1) \leftarrow p(X_1, X_2), p(X_2, X_1)$$

$$D_3 : q(X_1) \leftarrow \quad p(X_1, X_2), p(X_1, X_3), p(X_2, X_1),$$
$$p(X_2, X_3), p(X_3, X_1), p(X_3, X_2)$$

$$D_n : q(X_1) \leftarrow \{p(X_i, X_j) | 1 \leq i, j \leq n, i \neq j\}$$

$$\cdot$$

$$\cdots$$

$$C : q(X_1) \leftarrow p(X_1, X_1)$$

H θ-subsume e^+

et $|H| \leq_{\mathbb{N}} 5$

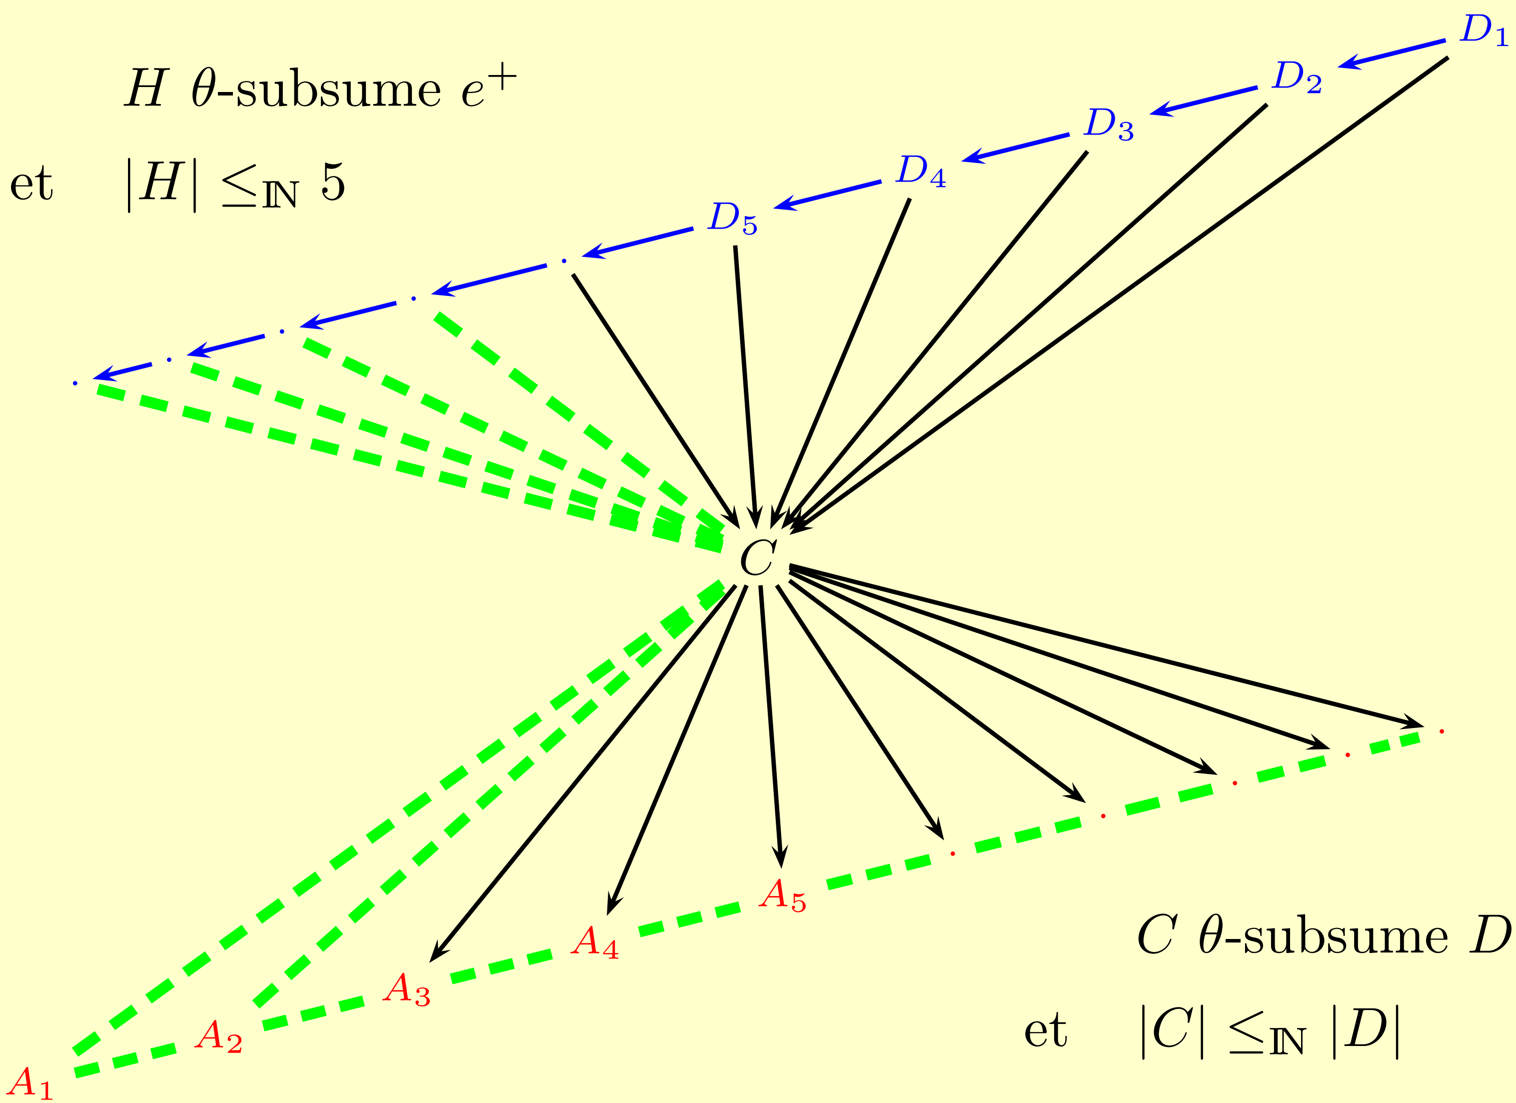

C θ-subsume D

et $|C| \leq_{\mathbb{N}} |D|$

Découverte d'un opérateur idéal

— Opérateur idéal pour $\succeq^{\theta}_{||}$

(2) Unifier deux variables X_1 et X_2 de C, telles que $C >^{\theta} C\{X_1/X_2\}$. Si la taille de la clause-résultat a diminué, ajouter un littéral ne contenant que des nouvelles variables.

— Résultats de non existence pour :
  - — une borne sur la profondeur des hypothèses,
  - — la limitation du nombre de variables utilisées.

— Piste : le biais MaxOcc (bornes sur l'occurrence de chaque symbole de prédicat dans les hypothèses).

Biais et générer-et-tester : bilan

— Propriétés privées.

— Élagage dynamique par rapport aux biais de langage basé sur l'utilisation de nouveaux pré-ordres : les *relations naturelles*.

[Shapiro, 1981]

— Conditions nécessaires sur les propriétés pour permettre l'existence d'opérateurs idéaux.

— Découverte d'un opérateur idéal pour $\succeq_{||}^{\theta}$.

[Champesme et al., 1995, Esposito et al., 1996]

— Cadre parfait : optimalité. [De Raedt and Bruynooghe, 1993]

Apprentissage disjonctif : problème du Morpion

— Caractériser les fins de jeu au morpion gagnantes pour les croix.

— La solution est la disjonction des huit manières de faire des lignes de croix :

×	?	?
×	?	?
×	?	?

?	×	?
?	×	?
?	×	?

?	?	×
?	?	×
?	?	×

×	?	?
?	×	?
?	?	×

?	?	×
?	×	?
×	?	?

×	×	×
?	?	?
?	?	?

?	?	?
×	×	×
?	?	?

?	?	?
?	?	?
×	×	×

Expérimentations sur le problème du Morpion

— On dispose de 958 exemples (toutes les fins de jeu possibles).

— On utilise 70 % des exemples pour apprendre, les 30 % restants pour le test.

default	65.3 %
NewID	84.0 %
CN2	98.1 %
MBRtalk	88.4 %

IB1	98.1 %
IB3	82.0 %
IB3-CI	99.1 %

[Aha, 1991]

Moindre généralisé

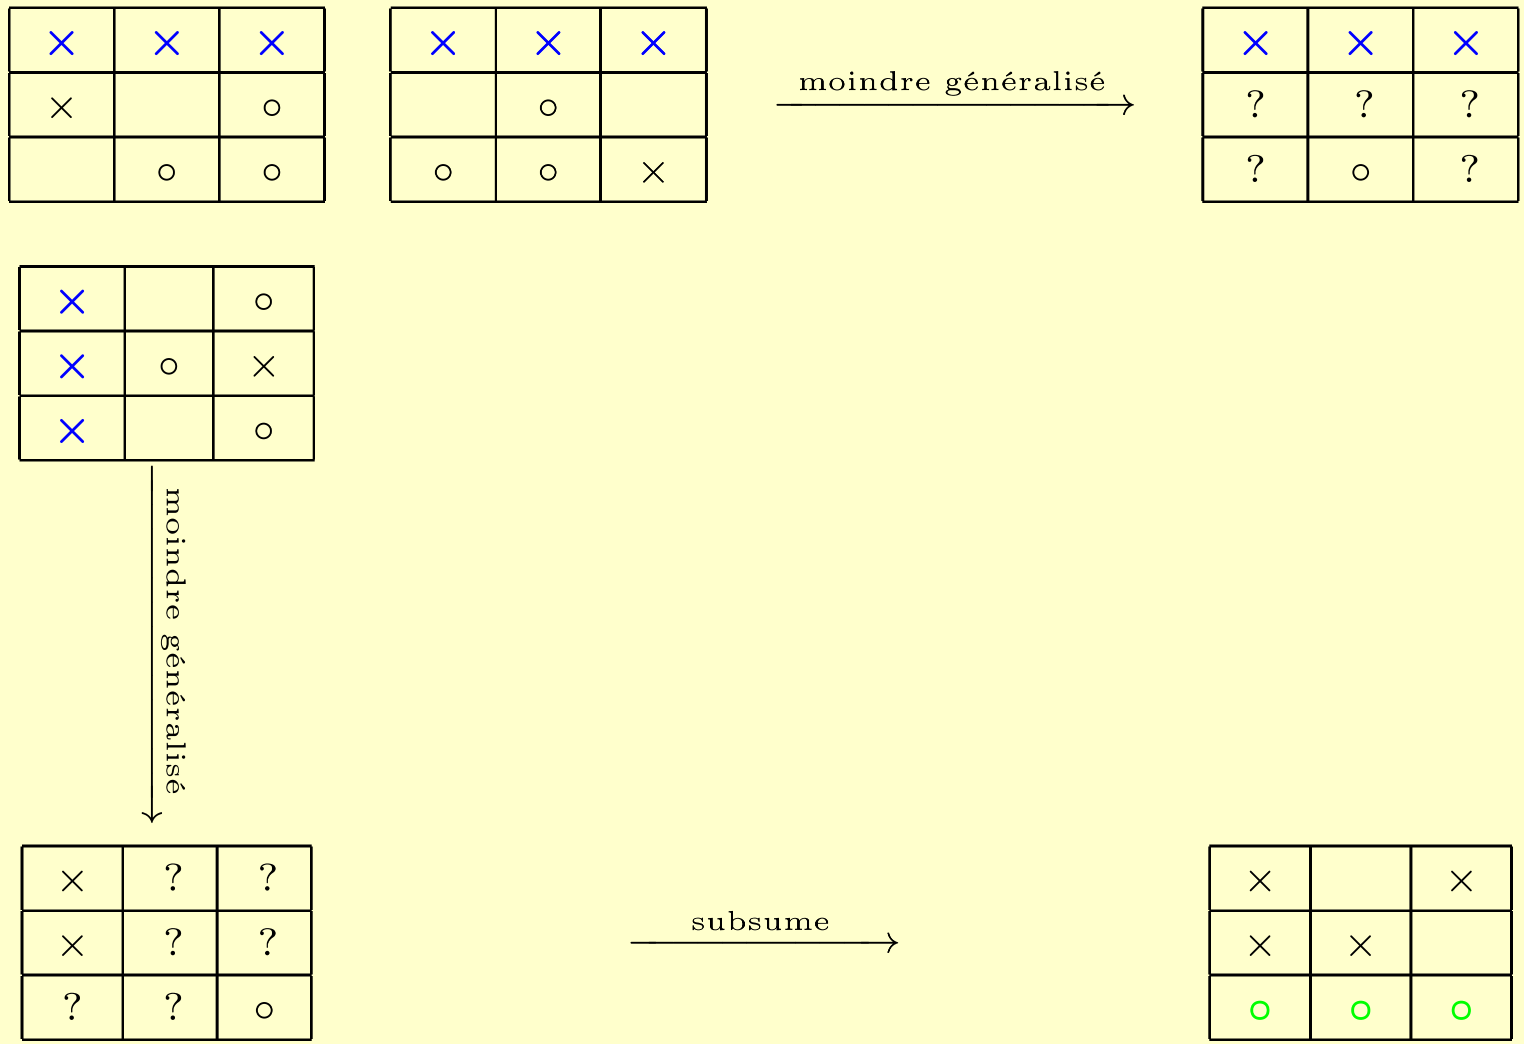

Apprentissage supervisé disjonctif

Différentes couvertures des exemples positifs :

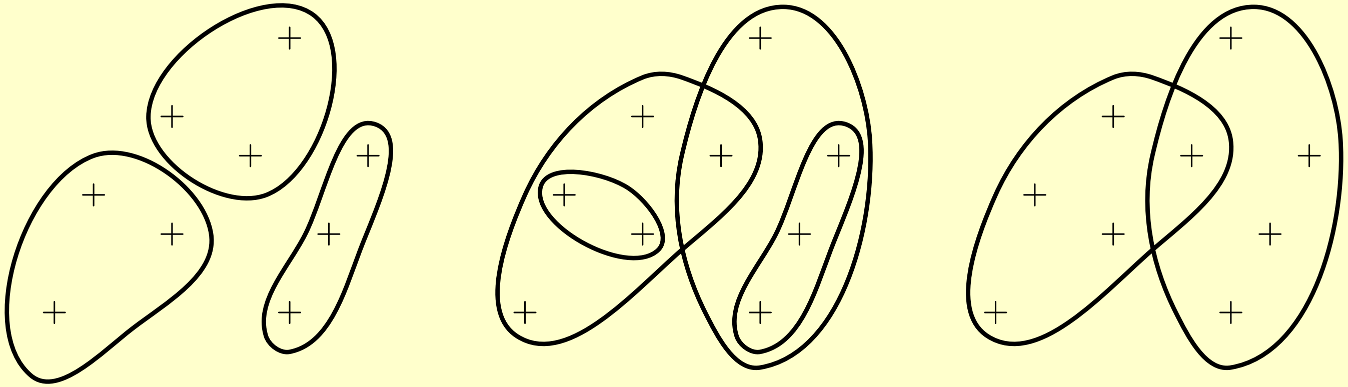

Difficile pour les approches par *couverture* et pour les méthodes de type *diviser pour régner*. [Boström, 1995]

Solution idéale : paquets maximalement corrects,

nombre minimal de paquets.

Problème NP-difficile.

Algorithme de GloBo : sélection stochastique

graine	autres positifs		paquet maximalement correct
p_1	$p_5\ p_8\ \cancel{p_2}\ p_{14}\ldots$	$\rightarrow$	$\{p_1, p_5, p_8, p_{14}, \ldots\}$
p_2	$\cancel{p_{14}}\ p_3\ \cancel{p_1}\ p_{12}\ldots$	$\rightarrow$	$\{p_2, p_3, p_{12}, \ldots\}$
p_3	$p_7\ \cancel{p_4}\ \cancel{p_{18}}\ \cancel{p_{12}}\ldots$	$\rightarrow$	$\{p_3, p_7, \ldots\}$
p_4	$p_{13}\ p_3\ \cancel{p_9}\ \cancel{p_{11}}\ldots$	$\rightarrow$	$\{p_4, p_{13}, p_3, \ldots\}$
p_5	$p_8\ \cancel{p_2}\ p_1\ p_{14}\ldots$	$\rightarrow$	$\{p_5, p_8, p_1, p_{14}, \ldots\}$
$\vdots$	$\ldots$	$\rightarrow$	$\ldots$

Paquets verrouillés et paquets condamnés

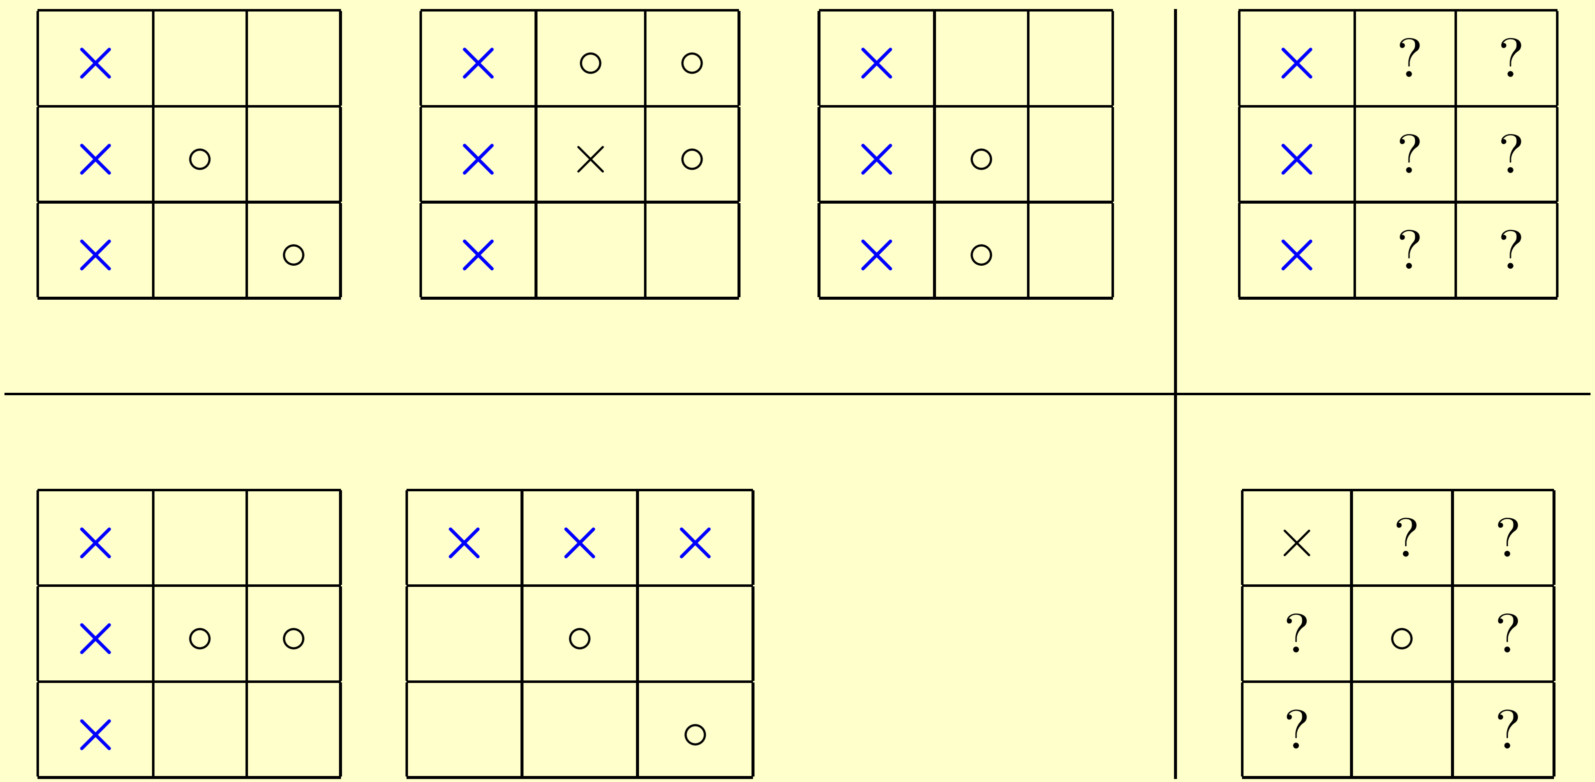

Algorithme de GloBo : couverture minimale

- Problème NP-difficile.
- Heuristique polynomiale : choisir le paquet qui couvre le plus d'éléments non encore couverts. [Paschos, 1997]

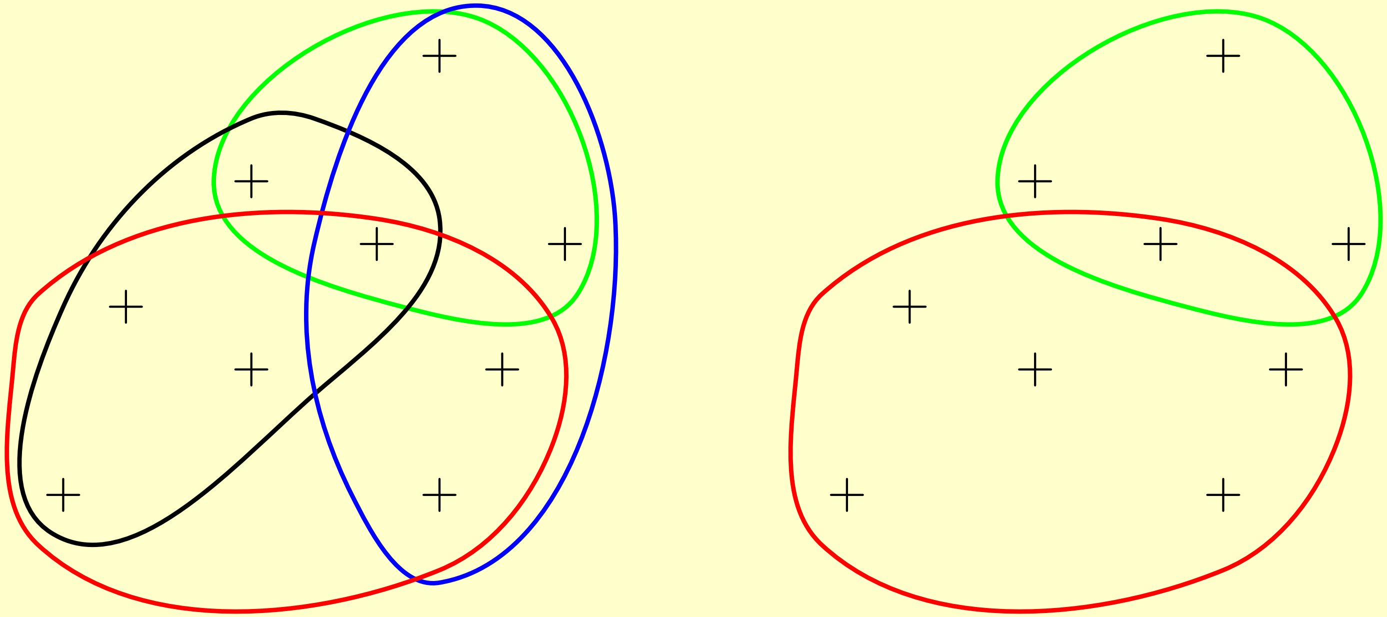

Complexité de GloBo

- Construction d'un paquet maximalement correct : $|A^+| - 1$ calculs de moindre généralisés et un test de couverture vis-à-vis de $|A^-|$ (au pire, $|A^-|$ tests de subsomption).
- Couverture minimale : $|A^+|^2$. [Paschos, 1997]
- GloBo : $\Theta(|A^+|^2)$ en calculs de moindre généralisé, et $\Theta((|A^+| + |A^-|)^3)$ en tests de subsomption.
- Pré-requis : unicité du moindre généralisé et la propriété de correction vérifie :

$$\text{Correct}(A \cup B) \Rightarrow \text{Correct}(A) \wedge \text{Correct}(B)$$

Estimation de la probabilité de réussite de l'apprentissage

n nombre de sous-concepts à apprendre,

s nombre moyen d'exemples positifs dans un sous-concept,

α la probabilité d'être favorable à la graine,

b la taille minimale d'un paquet verrouillé (hors graine).

événement	probabilité
verrouiller le paquet	α^b
échouer pour s exemples	$\left(1-\alpha^b\right)^s$
réussir pour n sous-concepts	$\left[1-\left(1-\alpha^b\right)^s\right]^n$

Intérêts de la probabilité de réussite

$$\left[1-\left(1-\alpha^{b}\right)^{s}\right]^{n}$$

— Fiabilité a posteriori de la solution découverte.
— Notion de représentativité des exemples disponibles par rapport au concept à découvrir.
— No Free Lunch Theorem : [Wolpert and Macready, 1995] [Schaffer, 1994]
caractérisation des cas d'échec.

Probabilité de succès de GloBo pour le morpion

$n = 8$, $\alpha = \frac{1}{2}$, $b = 2$ et s vaut $\frac{1}{8}$ du nombre d'exemples disponibles.

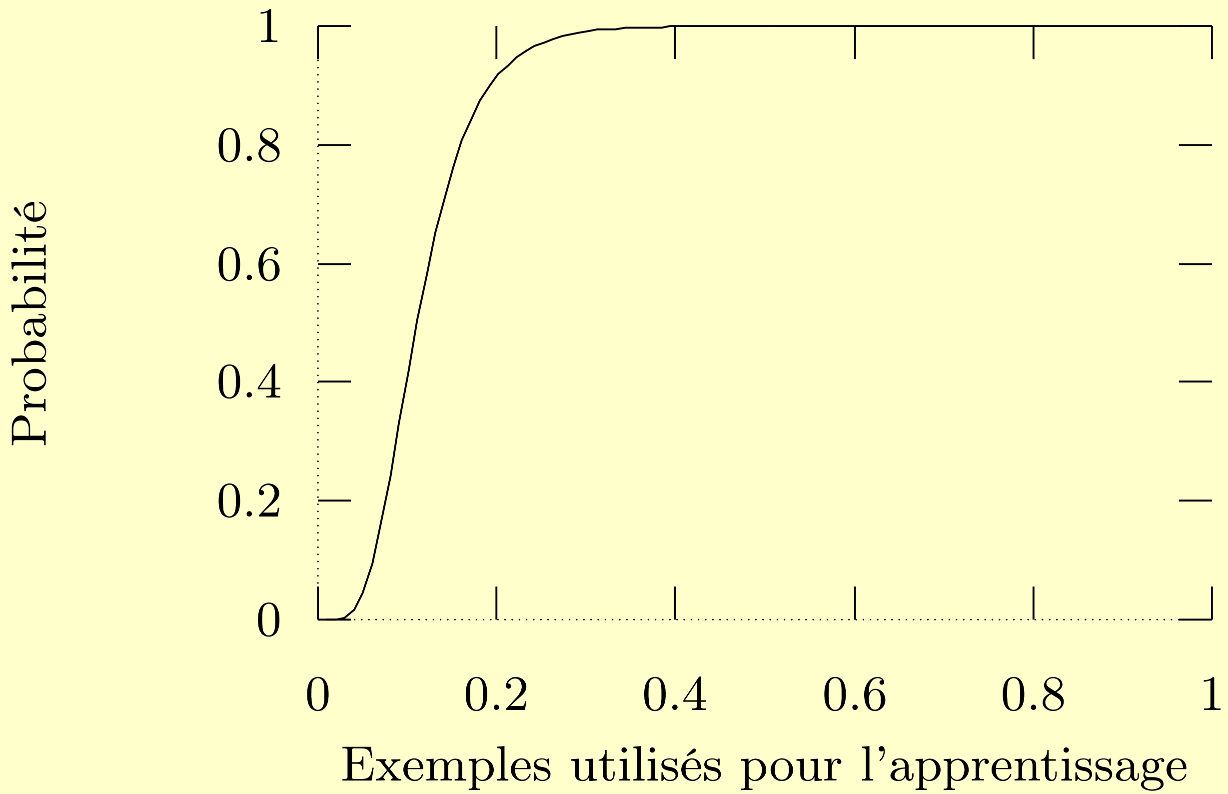

Résultats de GloBo pour le morpion

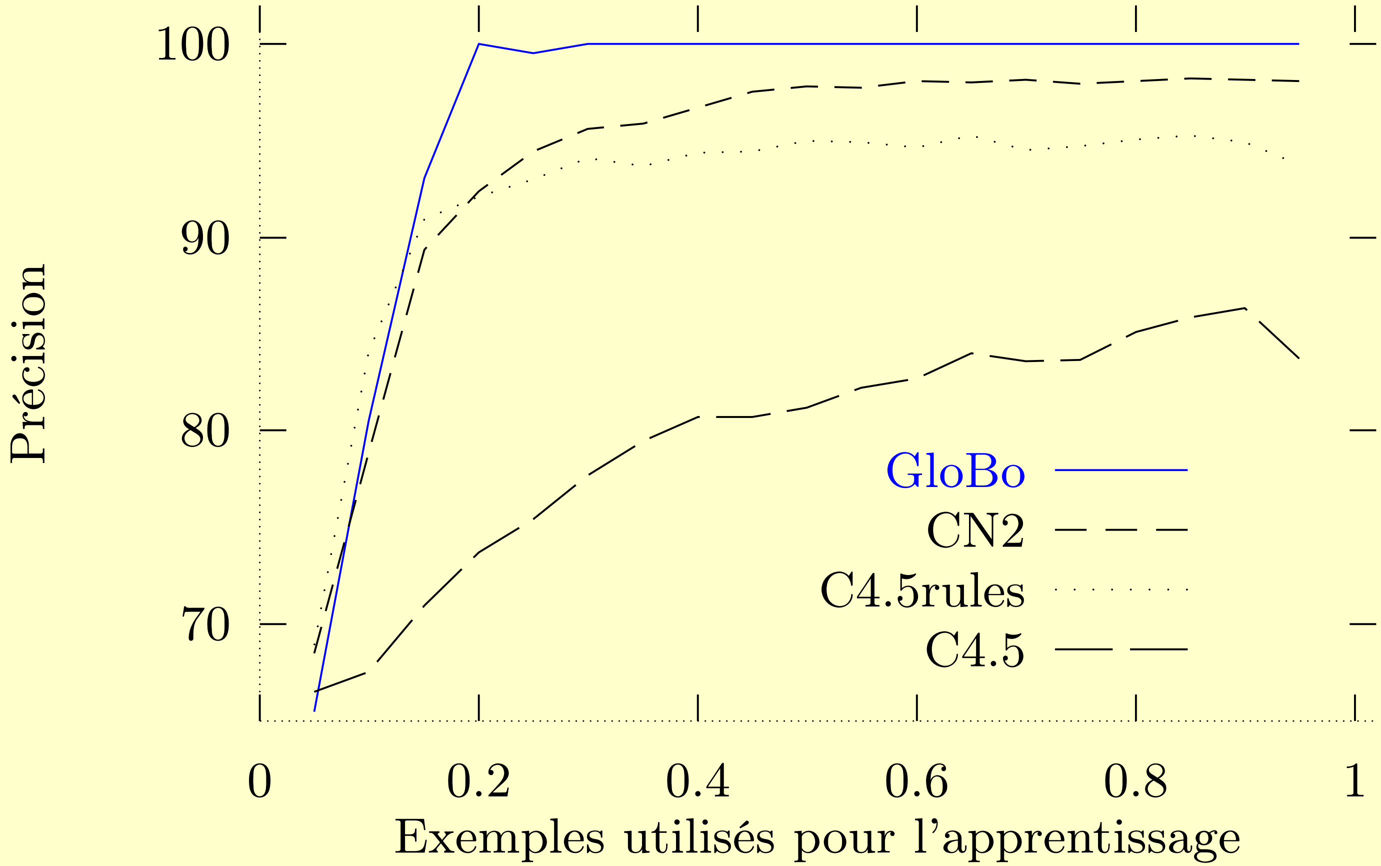

Autres expérimentations

Problème	Taille	Précision
Mushroom (avec négation)	3	100.0 %
Breast Cancer	4	93.0 %
Pima Indians Diabetes	24	68.8 %
Echocardiogram	3	88.2 %

PTE challenge : molécules cancérigènes. [Srinivasan et al., 1997]

Résultats : [Srinivasan et al., 1999]

— GloBo est premier des systèmes produisant une théorie compréhensible.

— GloBo est jugé optimal pour toute application pratique.

Apprentissage disjonctif : bilan

— Correction maximale et minimalité de la solution.

— Stochastique : pseudo-parallélisme et complexité raisonnable.

— Estimation du risque d'erreur de la procédure stochastique.

— Version générique : instanciations linéaire en temps, dédiée aux données bruitées, pour le non supervisé.

— Variation : les Vraizamis.

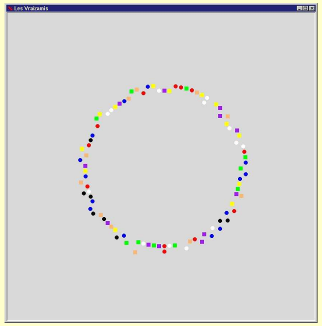

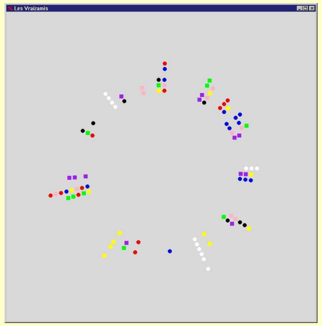

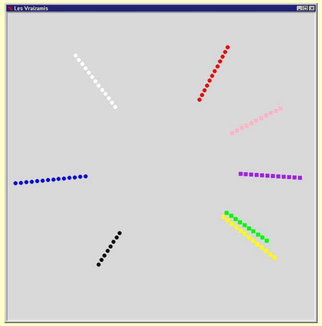

Conclusions

1. Apprentissage conjonctif en Programmation Logique Inductive
   — intégration des biais de langage dans la relation de généralité,
   — élagage intensif de l'espace de recherche.

2. Apprentissage disjonctif en attribut-valeur
   — couverture minimale par des paquets maximalement corrects,
   — construction stochastique des paquets,
   — approximation polynomiale d'une couverture minimale.

Perspectives

- Utiliser au mieux les connaissances de l'expert.
- Apprentissage disjonctif en Programmation Logique Inductive.
- Algorithmes d'évolution :
  - les Vraizamis, [Torre, 1999]
  - algorithmes génétiques parallèles, [Augier, 1999, Giordana et al., 1994]
  - utilisation de fourmis. [Monmarche et al., 1999]

Références

[Aha, 1991] Aha, D. W. (1991). Incremental constructive induction : An instance-based approach. In *Proceedings of the Eighth International Workshop on Machine Learning*, pages 117–121. Morgan Kaufmann.

[Augier, 1999] Augier, S. (1999). Changement d'échelle d'un algorithme d'apprentissage évolutionnaire. In [Sebag, 1999].

[Boström, 1995] Boström, H. (1995). Covering vs. divide-and-conquer for top-down induction of logic programs. In *Proceedings of the 14th International Joint Conference on Artificial Intelligence*, pages 1194–1200.

[Champesme et al., 1995] Champesme, M., Brézellec, P., and Soldano, H. (1995). Empirically conservative search space reductions. In Raedt, L. D., editor, *Proceedings of the 5th International Workshop on Inductive Logic Programming*, pages

387–402. Department of Computer Science, Katholieke Universiteit Leuven.

[De Raedt and Bruynooghe, 1993] De Raedt, L. and Bruynooghe, M. (1993). A theory of clausal discovery. In Bajcsy, R., editor, *Proceedings of the 13th International Joint Conference on Artificial Intelligence*, pages 1058–1063. Morgan Kaufmann.

[Esposito et al., 1996] Esposito, F., Laterza, A., Malerba, D., and Semeraro, G. (1996). Refinement of datalog programs. In *Proceedings of the MLnet Familiarization Workshop on Data Mining with Inductive Logic Programming (ILP for KDD)*, pages 73–94.

[Giordana et al., 1994] Giordana, A., Saitta, L., and Zini, F. (1994). Learning disjunctive concepts by means of genetic algorithms. In *Proc. 11th International Conference on Machine Learning*, pages 96–104. Morgan Kaufmann.

[Gottlob, 1987] Gottlob, G. (1987). Subsumption and implication. *Information Processing Letters*, 24(2) :109–111.

[Kapur and Narendran, 1986] Kapur, D. and Narendran, P. (1986). Np-completeness of the set unification and matching problems. In *Proceedings of 8th Conference on Automated Deduction*, volume 230, pages 489–495. Springer-Verlag.

[Mitchell, 1980] Mitchell, T. M. (1980). The need for biases in learning generalizations. In *Readings in Machine Learning*, pages 184–191. Morgan Kaufmann. Published in 1991.

[Mitchell, 1982] Mitchell, T. M. (1982). Generalization as search. *Artificial Intelligence*, 18 :203–226.

[Monmarche et al., 1999] Monmarche, N., Slimane, M., and Venturini, G. (1999). Antclass : Découverte de classes dans des données numériques grâce à l'hybridation d'une colonie de fourmis et de l'algorithme des centres mobiles. In [Sebag, 1999].

[Muggleton, 1991] Muggleton, S. (1991). Inductive logic programming. *New Generation Computing Journal*, 8(4) :295–317.

[Muggleton and Buntine, 1988] Muggleton, S. H. and Buntine, W. (1988). Machine invention of first-order predicates by inverting resolution. In *Proceedings 5th International Conference on Machine Learning*, pages 339–352, San Mateo, CA. Morgan Kaufmann.

[Nédellec et al., 1996] Nédellec, C., Rouveirol, C., Adé, H., Bergadano, F., and Tausend, B. (1996). Declarative bias in ILP. In De Raedt, L., editor, *Advances in Inductive Logic Programming*, pages 82–103. IOS Press.

[Paschos, 1997] Paschos, V. T. (1997). A survey of approximately optimal solutions to some covering and packing problems. *ACM Computing Surveys*, 29(2) :171–209.

[Plotkin, 1970] Plotkin, G. (1970). A note on inductive generalization. In Meltzer, B. and Mitchie, D., editors, *Machine Intelligence*, volume 5, pages 153–165. Edinburgh University Press.

[Schaffer, 1994] Schaffer, C. (1994). A conservation law for generalization performance. In Cohen, W. W. and Hirsh, H., editors, *Proceedings 11th International Conference on Machine Learning*, pages 259–265. Morgan Kaufmann.

[Schmidt-Schauss, 1988] Schmidt-Schauss, M. (1988). Implication of clauses is undecidable. *TCS : Theoretical Computer Science*, 59(3) :287–296.

[Sebag, 1999] Sebag, M., editor (1999). *Actes de la Première Conférence d'Apprentissage (CAP'99).*

[Shapiro, 1981] Shapiro, E. Y. (1981). Inductive inference of theories from facts. Technical Report 192, Yale University Department of Computer Science.

[Srinivasan et al., 1999] Srinivasan, A., King, R., and Bristol, D. (1999). An assessment of submissions made to the predictive toxicology evaluation challenge. In *Proceedings of the 16th International Joint Conference on Artificial Intelligence*, pages 270–276. Morgan Kaufmann.

[Srinivasan et al., 1997] Srinivasan, A., King, R. D., Muggleton, S. H., and Sternberg, M. J. E. (1997). The predictive toxicology evaluation challenge. In *Proceedings of the 15th International Joint Conference on Artificial Intelligence*, pages 4–9. Morgan Kaufmann.

[Torre, 1999] Torre, F. (1999). Les Vraizamis. In [Sebag, 1999], pages 177–184.

[Utgoff, 1986] Utgoff, P. E. (1986). Shift of bias for inductive concept learning. In Michalski, R. S., Carbonell, J. G., and Mitchell, T. M., editors, *Machine Learning : An Artificial*

Intelligence Approach, volume II, pages 107–148. Morgan Kaufmann.

[Utgoff and Mitchell, 1982] Utgoff, P. E. and Mitchell, T. M. (1982). Acquisition of appropriate bias for inductive concept learning. In Waltz, D., editor, *Proceedings of the National Conference on Artificial Intelligence*, pages 414–417. AAAI Press.

[van der Laag and Nienhuys-Cheng, 1994] van der Laag, P. R. J. and Nienhuys-Cheng, S. (1994). Existence and nonexistence of complete refinement operators. In Bergadano, F. and de Raedt, L., editors, *Proceedings of the 7th European Conference on Machine Learning*, volume 784 of *Lecture Notes in Artificial Intelligence*, pages 307–322. Springer-Verlag.

[Wolpert and Macready, 1995] Wolpert, D. H. and Macready, W. G. (1995). No free lunch theorems for search. Technical Report SFI-TR-95-02-010, The Santa Fe Institute.