GloBo

Fabien Torre (fabien@lri.fr)

Équipe Inférence et Apprentissage

Laboratoire de Recherche en Informatique

Université Paris-Sud, Orsay

CAP'99 - 17 juin 1999

Plan de l'exposé

– Apprentissage supervisé disjonctif et apprentissage non supervisé
– Algorithme stochastique de GloBo
– Critère de réussite
– Expérimentations

Apprentissage supervisé conjonctif

$\mathbf{E}^+$	$\mathbf{E}^-$
x,x,x,x,o,o,x,o,o	x,b,x,o,o,o,b,b,x
x,x,x,x,o,o,o,x,o	x,b,o,x,b,o,b,x,o
x,x,x,x,o,b,o,o,b	o,x,x,x,o,x,o,b,o
x,x,x,x,o,b,b,o,o	o,x,x,o,o,b,x,x,o
x,x,x,x,b,o,o,o,b	o,x,b,x,o,x,x,o,o
x,x,x,x,b,o,o,b,o	o,o,x,o,x,b,o,x,x
x,x,x,o,x,o,o,o,x	o,o,o,x,b,b,b,x,x
x,x,x,o,x,o,b,o,b	o,b,x,x,o,o,x,x,o
x,x,x,o,x,o,b,b,o	o,b,b,o,x,x,o,b,x
x,x,x,o,x,b,o,o,b	b,x,o,x,o,b,o,x,b
x,x,x,o,x,b,b,o,o	b,o,o,x,o,x,x,o,x

$\text{mg}(E^+) = \text{x,x,x,?,?,?,?,?,?}$

Apprentissage supervisé disjonctif

$\mathbf{E}^+$	$\mathbf{E}^-$
x,x,x,o,x,o,o,x,o	x,b,x,o,o,o,b,b,x
x,x,o,x,o,b,x,b,o	x,b,o,x,b,o,b,x,o
x,o,o,x,x,o,x,b,b	o,x,x,x,o,x,o,b,o
x,o,b,b,x,o,o,x,x	o,x,x,o,o,b,x,x,o
x,b,b,x,o,b,x,b,o	o,x,b,x,o,x,x,o,o
o,x,b,x,x,o,o,x,b	o,o,x,o,x,b,o,x,x
o,o,b,x,x,x,b,b,b	o,o,o,x,b,b,b,x,x
o,b,b,o,o,x,x,x,x	o,b,x,x,o,o,x,x,o
b,o,x,o,b,x,o,x,x	o,b,b,o,x,x,o,b,x
b,b,x,b,o,x,o,b,x	b,x,o,x,o,b,o,x,b
b,b,b,o,o,b,x,x,x	b,o,o,x,o,x,x,o,x

$$\text{mg}(E^+) = ?,?,?,?,?,?,?,?,?$$

Difficultés de l'apprentissage supervisé disjonctif

Conjonctif : toutes les solutions sont équivalentes

Disjonctif : différentes couvertures des exemples positifs

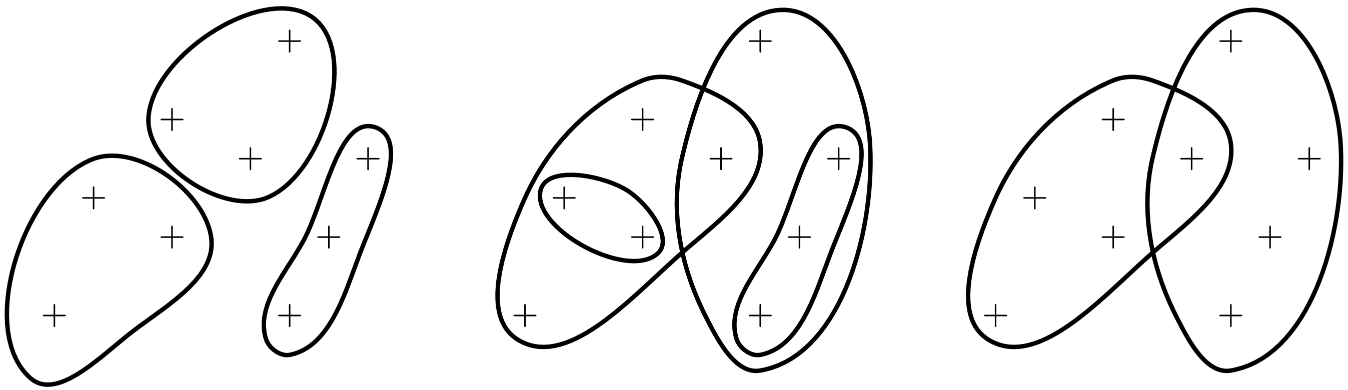

Difficile pour les approches par couverture et pour les méthodes de type diviser pour régner [Boström, 1995].

Problème du Morpion

Caractériser les fins de jeu au morpion qui sont gagnantes pour les croix : la solution est la disjonction des huit manières de faire des lignes de croix. On dispose de 958 exemples.

Expérimentations : on utilise 70 % des exemples pour apprendre, les 30 % restants pour le test [Aha, 1991].

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

IB1	98.1 %
IB3	82.0 %
IB3-CI	99.1 %

Problème général

Étant donné un ensemble E et une propriété P sur les sous-ensembles de E, trouver une couverture minimale de E utilisant des sous-ensembles de E qui soient maximalement admissibles par rapport à P.

supervisé : $P(S) \Leftrightarrow \forall n \in E^{-}, \mathrm{mg}(S) \not\geq n$

non supervisé : $P(S) \Leftrightarrow \forall (a,b) \in S, d(a,b) \leq d_{max}$

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

$\times$		
$\times$	$\circ$	
$\times$		$\circ$

$\times$	$\circ$	$\circ$
$\times$	$\times$	$\circ$
$\times$		

$\times$		
$\times$	$\circ$	
$\times$	$\circ$	

$\times$	?	?
$\times$	?	?
$\times$	?	?

$\times$		
$\times$	$\circ$	$\circ$
$\times$		

$\times$	$\times$	$\times$
	$\circ$	
		$\circ$

$\times$	?	?
?	$\circ$	?
?		?

Algorithme de GloBo : couverture minimale

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

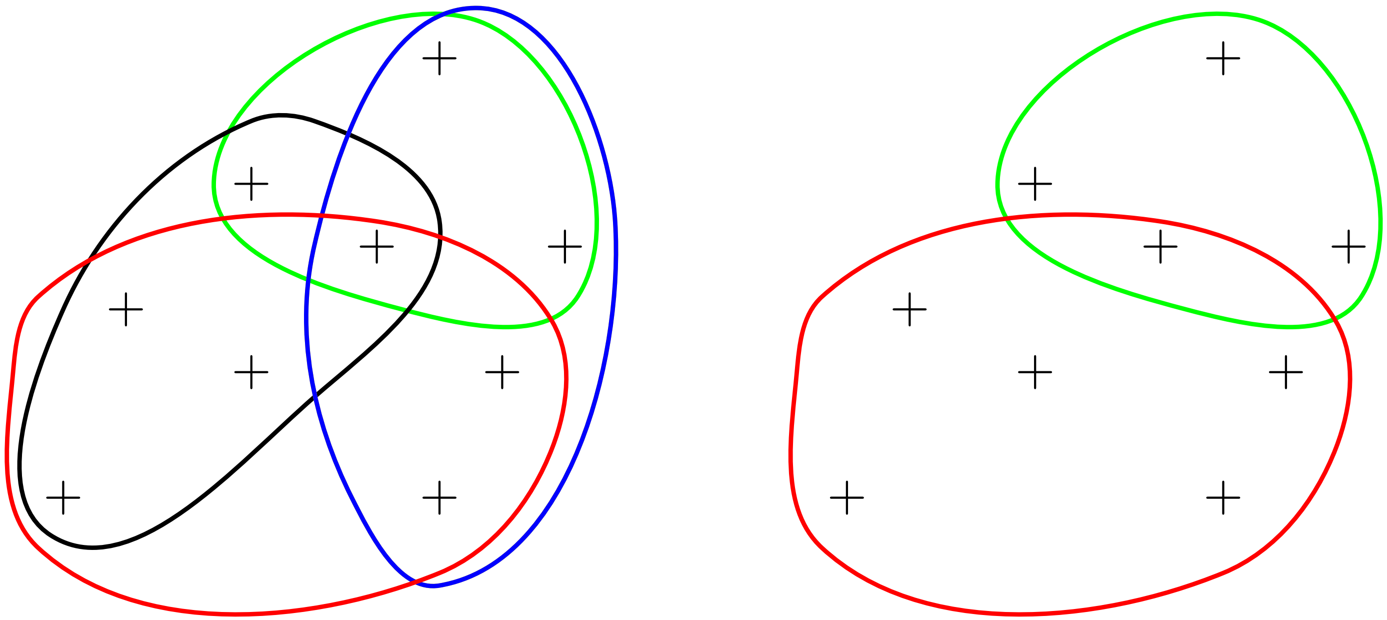

Complexité de GloBo

- Construction d'un paquet maximalement consistant : $|E| - 1$ calculs d'agrégation et on fait un test de la propriété P pour chacune de ces agrégations.
- Couverture minimale : $|E|^2$ [Paschos, 1997].
- GloBo supervisé : $\Theta((|E^+| + |E^-|)^2)$ en calculs de moindre généralisé, et $\Theta((|E^+| + |E^-|)^3)$ en tests de subsomption.
- Conditions d'application : $P(A \cup B) \Rightarrow P(A) \wedge P(B)$ et unicité du moindre généralisé.

Probabilité de réussite du clustering (1)

n nombre de sous-concepts à apprendre,

s nombre moyen d'éléments de E dans un sous-concept,

α la probabilité de compatibilité avec la graine,

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

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

Probabilité de réussite du clustering (2)

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

- A posteriori, confiance dans 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 8% de la taille du dataset.

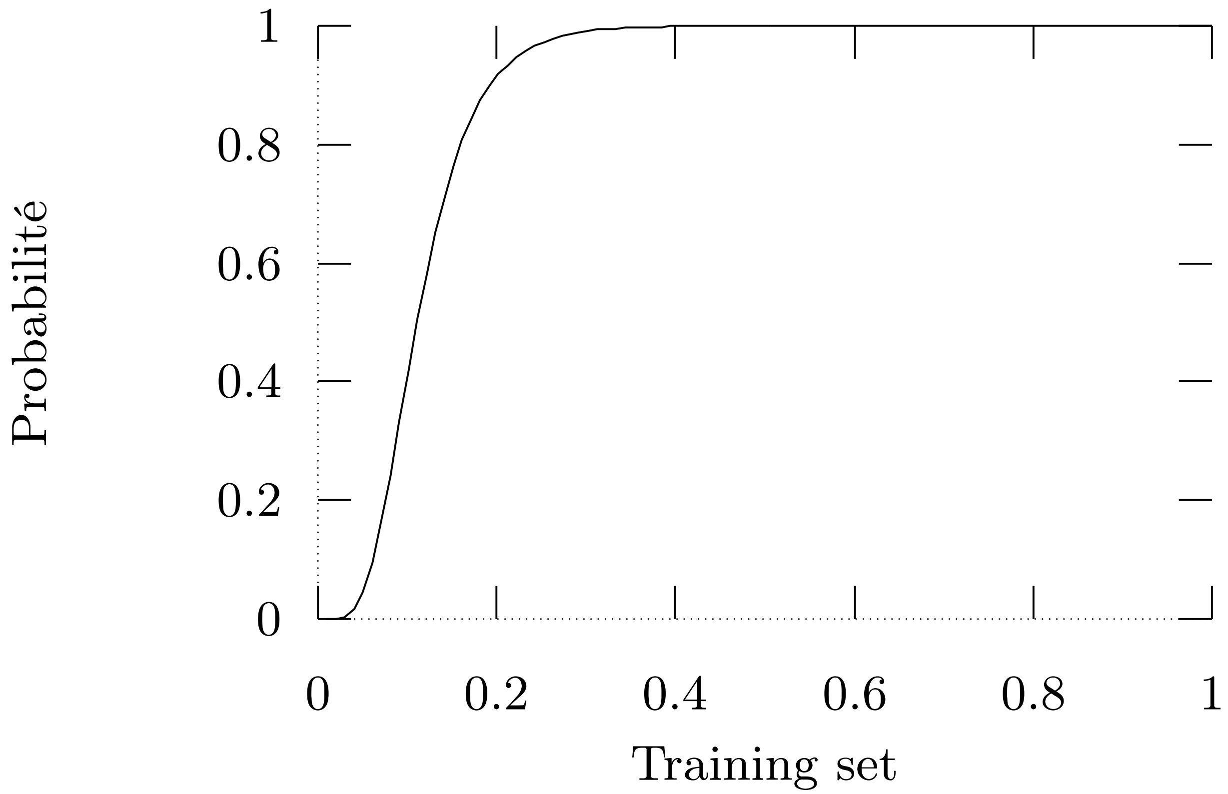

Résultats de GloBo pour le morpion

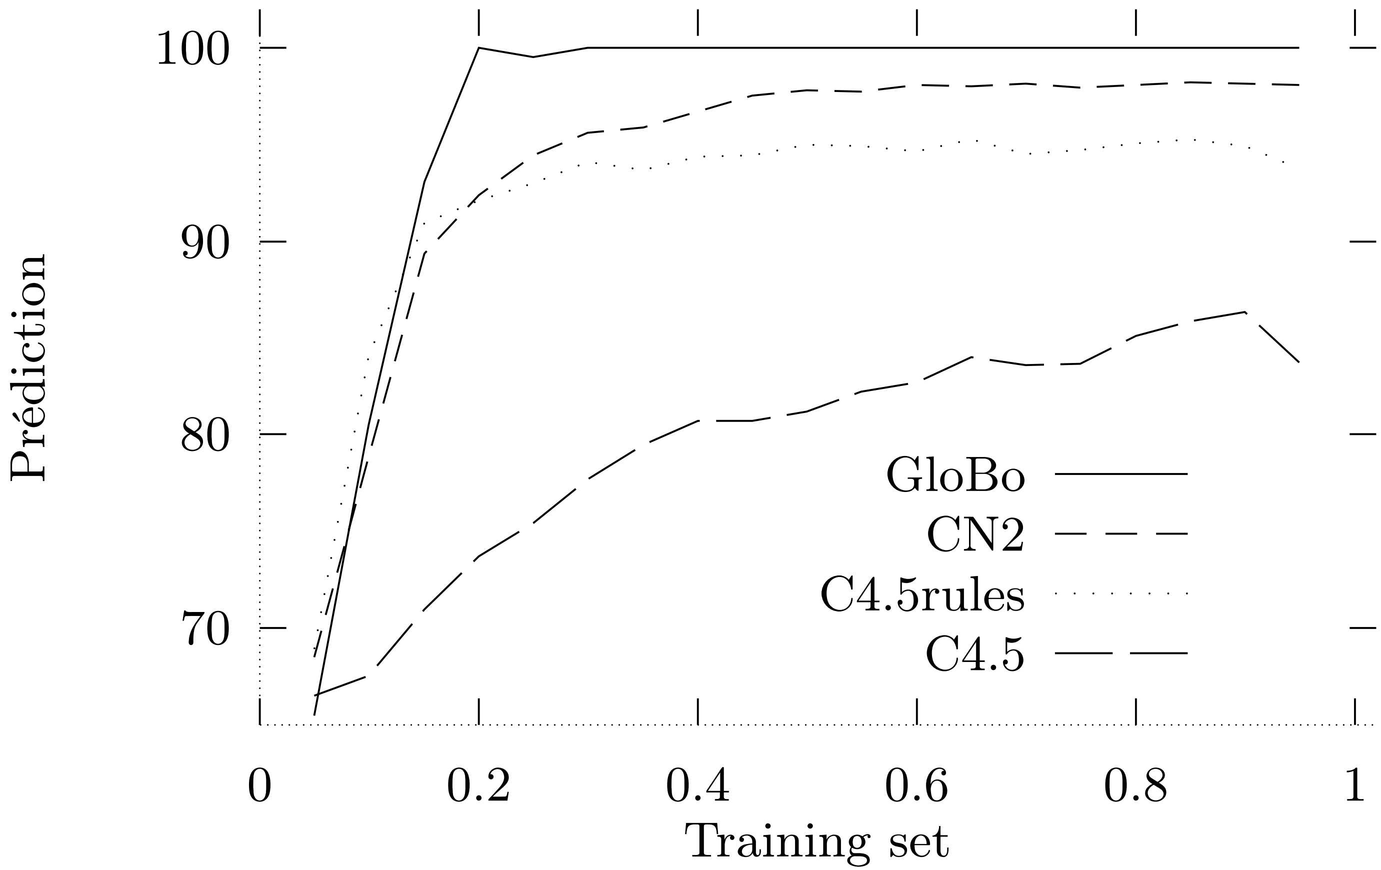

Autres expérimentations

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

PTE challenge [Srinivasan et al., 1997] : GloBo est premier ou deuxième, selon le critère considéré [Srinivasan et al., 1999a, Srinivasan et al., 1999b].

Quadruped animals [Gennari et al., 1989]

- Chaque instance appartient à l'une des quatre classes suivantes : chiens, chats, chevaux ou girafes.
- Chaque animal est décrit par 8 composantes : le cou, quatre jambes, le tronc, la tête, et la queue. Chacun de ces éléments est représenté par un cylindre, lui-même défini par 9 attributs.
- Utilisation de 100 exemples générés aléatoirement.
- Distance euclidienne.
- Minimiser à la fois le nombre de paquets et la distance intra-cluster : on observe le produit.

Réglage empirique de la distance limite

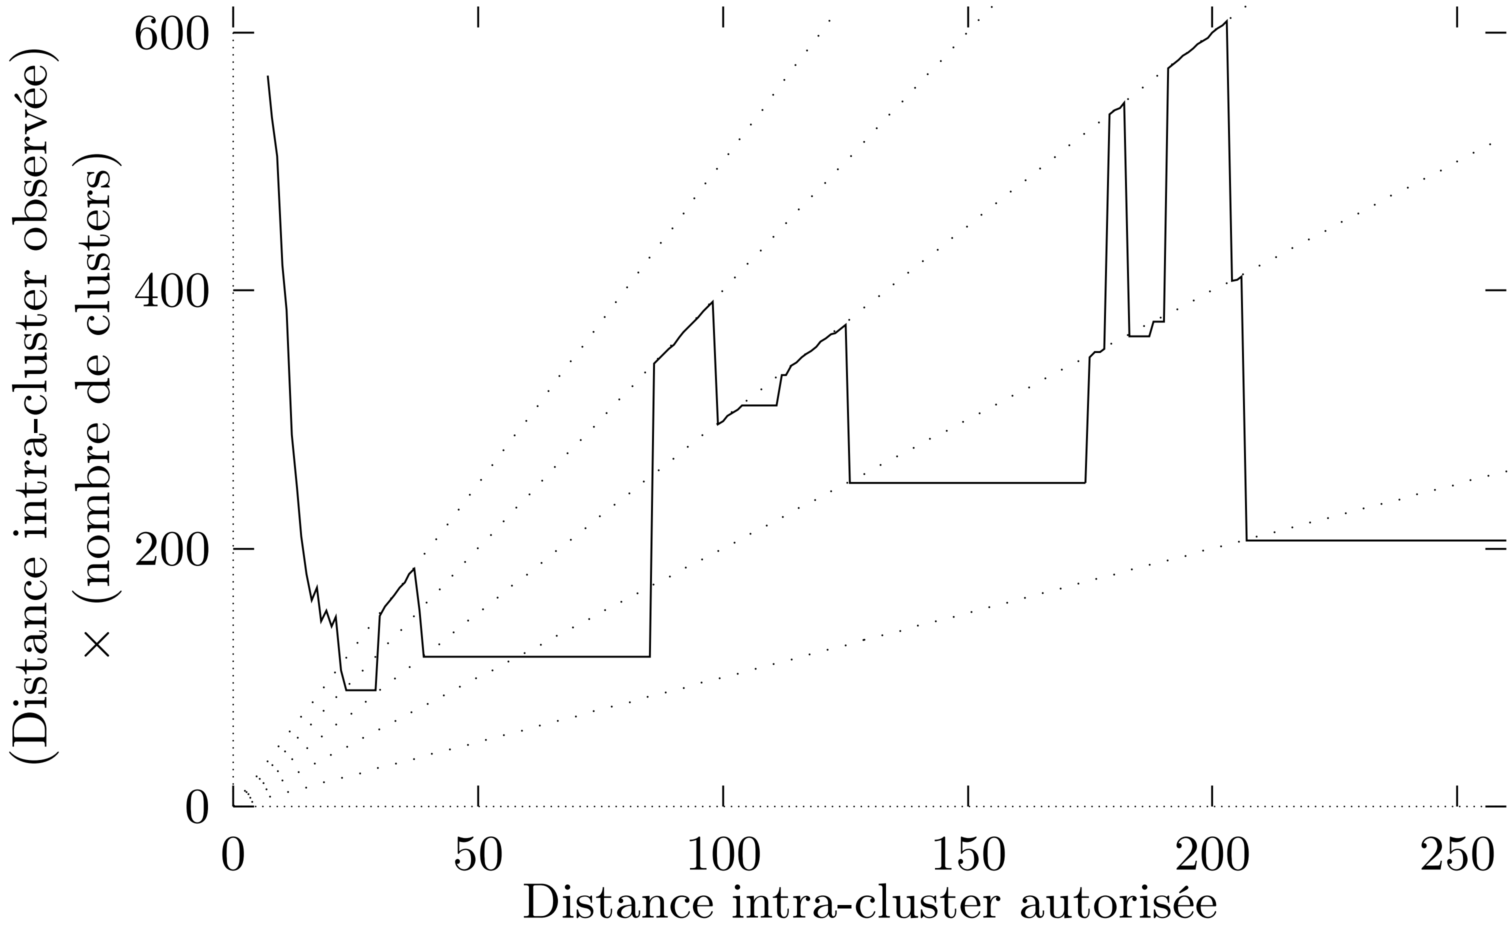

Conclusion

Bilan :

- Algorithme pour le supervisé ou non ;
- Stochastique pour obtenir une complexité raisonnable ;
- Estimation du risque d'erreur de la procédure stochastique ;
- Moindre généralisé comme apprentissage conjonctif.

Perspectives :

- Données bruitées ;
- Autres langages.

Références

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

[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.

[Gennari et al., 1989] Gennari, J. H., Langley, P., and Fisher, D. (1989). Models of incremental concept formation. Artificial Intelligence, 40:11–61.

[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.

[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.

[Srinivasan et al., 1999a] Srinivasan, A., King, R., and Bristol, D. (1999a). An assessment of ILP-assisted models for toxicology and the PTE-3 experiment. In Džeroski, S. and Flach, P., editors, Proceedings of the 9th International Workshop on Inductive Logic Programming, volume 1634 of Lecture Notes in Artificial Intelligence. Springer-Verlag. À paraître.

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

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

[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.