



HAL
open science

HLS : expérimentations d'un système neuro-symbolique

Jihane Boulahia-Smirani, Laurent Bougrain

► **To cite this version:**

Jihane Boulahia-Smirani, Laurent Bougrain. HLS : expérimentations d'un système neuro-symbolique. Traitement et Analyse de l'Information : Méthodes et Applications - TAIMA'2005, Sep 2005, Hammamet/Tunisie, pp.410-415. inria-00000665

HAL Id: inria-00000665

<https://inria.hal.science/inria-00000665>

Submitted on 14 Nov 2005

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

HLS : expérimentations d'un système neuro-symbolique

Jihane Boulahia-Smirani¹ et Laurent Bougrain²

¹ ENSI/LIA. Artificial Intelligence Group Tunis, Tunisie
jihanesmirani@yahoo.fr

² Université Henri Poincaré - Nancy 1
projet Cortex, LORIA (UMR 7503)
campus scientifique, BP 239
54506 Vandœuvre-lès-Nancy Cedex, France
Laurent.bougrain@loria.fr

Résumé Dans cet article, nous discutons des propriétés d'un système d'apprentissage hybride neuro-symbolique nommé HLS (Hybrid Learning System) proposé par J. Boulahia-Smirani. Le système HLS possède des modules capables de réaliser un transfert d'information bidirectionnel entre un module symbolique et un module connexionniste. Nous présentons différentes expérimentations qui mettent en évidence divers points forts du système HLS que sont : la capacité d'intégrer des connaissances théoriques (règles) et des connaissances empiriques (exemples), la capacité de prendre une base de connaissances initiales (règles) de la convertir en un réseau connexionniste, d'utiliser des connaissances empiriques qui par apprentissage permettent de réviser les connaissances théoriques, d'acquérir de nouvelles connaissances et d'explicitier ces nouvelles connaissances acquises et enfin la capacité d'améliorer les performances des simples systèmes symboliques ou connexionnistes.

Mots clés système hybride neuro-symbolique, réseaux de neurones, insertion de règles symboliques, extraction de règles symboliques.

1 Introduction

En Intelligence Artificielle une technique particulière, même sophistiquée, permet rarement la résolution d'un problème complexe. Chaque méthode comporte des points forts, mais aussi des limitations. C'est pour cela que l'hybridation est une démarche intéressante. La réalisation de systèmes hybrides permet de combiner les points forts de chaque approche, d'obtenir ainsi des performances plus élevées et d'élargir leur champ d'application [4,7].

Dans cet article, nous présenterons dans un premier temps notre système d'apprentissage hybride neuro-symbolique nommé HLS (Hybrid Learning System) [1,2] capable de réaliser un transfert bidirectionnel d'information entre un module symbolique et un module connexionniste. Puis, dans un deuxième temps, nous illustrerons ses performances sur divers problèmes.

2 HLS : Hybrid Learning System

Notre système hybride HLS comporte quatre phases [8,9]. Il permet le transfert de « connaissances théoriques », représentées par un ensemble de règles symboliques vers un module connexionniste. Ce transfert est réalisé à travers un compilateur de règles en réseau de neurones. Le réseau obtenu subit un apprentissage supervisé à partir d'un ensemble d'exemples, qui représente l'ensemble des « connaissances pratiques » [3]. Après l'amélioration des connaissances du réseau par apprentissage de la base de connaissances pratiques, on peut extraire les nouvelles informations acquises par le réseau sous forme de règles symboliques par l'application de notre algorithme d'extraction de règles ANREX (An Algorithm for Neural Rule EXtraction) [5,6].

3 Expérimentations

Afin d'illustrer les capacités du système HLS, nous détaillons ici les résultats enregistrés sur différents problèmes de discrimination issus de l'ensemble des bases de données de l'UCI destiné à tester et comparer les performances de différentes méthodes d'apprentissage en intelligence artificielle [10].

3.1 Rapidité de convergence et performances

Nous avons utilisé dans un premier temps la base des iris pour mettre en valeur deux caractéristiques principales de notre système HLS : la possibilité d'utiliser et d'intégrer des connaissances théoriques et empiriques et la capacité de profiter des connaissances théoriques de départ afin d'accélérer le processus d'apprentissage.

Pour cette expérimentation 100 réseaux sont entraînés afin d'apprendre à discriminer 3 classes d'iris à partir de 4 attributs quantitatifs. Chacun de ces réseaux est élagué tant que le taux de bonne classification en apprentissage reste supérieur à 95%. Les réseaux avec les plus petits nombres de connexions et un taux de précision supérieur à 97% sont sauvegardés. Au début nous avons pris la totalité de l'ensemble d'apprentissage composé de 150 exemples ensuite 75 de la taille originale et enfin que 50. Ensuite nous avons effectué des expérimentations sur des combinaisons de partitions de la base d'exemples et la base de règles afin de voir le comportement de notre système en présence d'un ensemble incomplet de connaissances théoriques et empiriques.

Pour cela nous avons tout d'abord inséré la base de règles disponible dans le réseau et ensuite nous avons raffiné les connaissances par apprentissage à partir des exemples disponibles. Les résultats de ces expérimentations sont récapitulés dans la figure 1, où nous indiquons le taux de généralisation et le nombre d'époques nécessaires pour arriver à ces résultats.

Les résultats enregistrés (tableau 1) montrent bien que le taux de généralisation de HLS dépasse la simple généralisation d'un réseau de neurones (figure 1) et que le système a su profiter de la présence simultanée des connaissances théoriques et des connaissances empiriques. Cette expérience montre que la combinaison des connaissances théoriques (règles) et des connaissances empiriques (exemples) en utilisant une approche hybride nous permet d'améliorer les performances du système. Le système HLS est capable d'utiliser les différentes connaissances disponibles sur le problème de façon à accélérer le processus d'apprentissage et à augmenter sa capacité de généralisation par rapport à l'utilisation d'un simple réseau de neurones.

Tableau 1 : Performances enregistrées avec la base des iris (moyenne de 20 tests).

Portion des règles	Portion des exemples	Généralisation avec un RNA	Généralisation avec HLS
	100%	97.5% 99 cycles	97.5% 99 cycles
	75%	87.3% 345 cycles	87.3% 345 cycles
	50%	70.42% 296 cycles	70.42% 296 cycles
100%			97.5% 68 cycles
75%			82.4% 249 cycles
50%			72.54% 256 cycles
75%	100%	97.5% 99 cycles	98.8% 53 cycles
50%	100%	97.5% 99 cycles	98.3% 51 cycles
75%	75%	87.3% 345 cycles	91.42% 56 cycles
75%	50%	70.42% 296 cycles	91.12% 96 cycles
50%	75%	87.3% 345 cycles	91.12% 95 cycles
50%	50%	70.42% 296 cycles	81.34% 120 cycles





Figure 1 : Nombre de cycles (à gauche) et pourcentage de bonnes classifications en généralisation (à droite) enregistrés avec la base des iris par HLS et un perceptron multicouches (RNA).

3.2 Intégration et extraction de règles par le système HLS

La particularité des bases de données des moines est que les règles ayant générées les exemples sont connues. Notre expérimentation porte sur le premier problème des moines. Elle consiste à lancer l'apprentissage du HLS en ne fournissant que 75% des règles connues (figure 2) pour étudier comment notre système réagit face à des connaissances théoriques manquantes. Nous avons donc éliminé une règle parmi les quatre connues, nous avons lancé le module d'insertion des règles, puis l'apprentissage du réseau et enfin le module d'extraction des règles. Ce processus a été répété pour toutes les configurations possibles d'élimination d'une règle parmi les quatre initiales. Dans tous les cas le système a pu retrouver la règle éliminée de l'ensemble d'origine.

<i>Règle éliminée :</i>	
<i>Si forme-tête = ronde Et forme-corps= ronde Alors c'est Monk1</i>	
<i>Règles extraites :</i>	
<i>Si forme-corps = octogone</i>	<i>Alors Non(H1)</i>
<i>Si forme-corps = carrée</i>	<i>Alors Non(H1)</i>
<i>Si forme-tête = octogone</i>	<i>Alors Non(H1)</i>
<i>Si forme-corps = carrée</i>	<i>Alors Non(H1)</i>
<i>Si forme-tête = ronde</i>	<i>Alors (H1)</i>
<i>Si forme-corps=ronde</i>	<i>Alors (H1)</i>
<i>Si H1</i>	<i>Alors Monk1</i>
<i>Règle finale :</i>	
<i>Si forme-tête = ronde Et forme-corps=ronde Alors Monk1</i>	

Figure 2 : Expérience des données incomplètes avec la base des moines.

Nous avons également, dans le même cadre, éliminé 50% de la base de règles (soit deux règles sur quatre) et après apprentissage, notre système a pu retrouver les deux règles éliminées.

Le système HLS est donc capable de prendre une base de connaissances initiales (règles) de la convertir en un réseau d'ajouter des connaissances par apprentissage et enfin d'expliquer les nouvelles connaissances acquises.

Un deuxième type d'expérimentation a été effectué sur les moines à savoir l'apport de l'existence simultanée des connaissances théoriques et empiriques sur la capacité de généralisation et l'accélération de ce processus (nombre d'époques nécessaires). Pour cela nous avons comparé les capacités de généralisation de notre système hybride HLS qui utilise une base d'exemples et une base de règles avec un simple réseau de neurones qui ne généralise qu'à partir d'une base d'exemples. Les tests ont d'abord été effectués avec 100%, 75% et 50% des exemples, puis 100%, 75% et 50% des règles et enfin l'utilisation simultanée des règles et exemples avec différentes combinaisons de proportions. Les résultats enregistrés sont illustrés dans le tableau 2. Ces expérimentations sur la base des moines ont montré que notre système HLS est capable de profiter de l'existence de différents types de connaissances en apprentissage, d'améliorer et d'accélérer le processus de généralisation.

Tableau 2 : Performances enregistrées avec la base des moines par HLS (moyenne de 20 tests)

<i>Portion des règles</i>	<i>Portion des exemples</i>	<i>Généralisation avec un RNA</i>		<i>Généralisation avec HLS</i>	
	100%	100%	109 cycles	100%	109 cycles
	75%	82,31%	297 cycles	82,31%	297 cycles
	50%	69,8 %	276 cycles	69,8 %	276 cycles
100%				100%	82 cycles
75%				82.4%	156 cycles
50%				67.54%	145 cycles
75%	100%	100%	109 cycles	100%	53 cycles
50%	100%	100%	109 cycles	100%	71 cycles
75%	75%	82,31%	297 cycles	97.42%	156 cycles
75%	50%	69,8 %	276 cycles	91.12%	96 cycles
50%	75%	82,31%	297 cycles	90.12%	95 cycles
50%	50%	69,8 %	276 cycles	81.34%	120 cycles

Rappelons qu'en plus de l'amélioration des performances du réseau en généralisation avec cette hybridation neuro-symbolique, le système HLS a su réagir face aux données manquantes en détectant correctement, les règles manquantes.

3.3 Comparaison de performances entre HLS, un arbre de décision et un réseau de neurones

Nous avons également comparé les performances de notre système avec deux autres techniques d'apprentissage automatique bien connues pour leurs efficacités : l'arbre de décision C4.5 et un perceptron multicouches. La tâche consiste à diagnostiquer si une tumeur décrite par 9 caractéristiques extraites d'une mammographie est bénigne ou maligne. Il existe 699 exemples dont 65% sont des cas bénignes. 525 exemples ont été utilisés pour l'apprentissage et 174 exemples pour le test. L'apprentissage n'est arrêté que si le taux d'apprentissage dépasse 98 %. Cette procédure est répétée 100 fois. Comme le montre la figure 3, nous constatons que les meilleurs résultats de généralisation ont été obtenus par HLS.

4 Conclusion

Nous avons présenté dans cet article les performances d'un nouveau système hybride neuro-symbolique HLS. Les résultats enregistrés mettent en évidence les divers points forts du système HLS :

1. La capacité d'intégrer des connaissances théoriques (règles) et des connaissances empiriques (exemples) avec des performances élevées.
2. La capacité de prendre une base de connaissances initiales (règles) de la convertir en un réseau, d'ajouter des connaissances par apprentissage et enfin d'expliquer les nouvelles connaissances acquises.
3. La capacité à dépasser les performances des simples systèmes symboliques ou connexionnistes.




Figure 3 : Pourcentages de bonnes classifications en généralisation enregistrés avec la base du cancer du sein pour le système hybride HLS, l'arbre de décision C4.5 et un perceptron multicouches (MLP).

Références

- [1] R. Andrews, J. Diederich, A.B. Tickle. A Survey And Critique of Techniques For Extracting Rules From Trained ANN. *Technical Report – Neurocomputing Research Centre, Queensland University of Technology*. Brisbane, Australia. January 1995.
- [2] M. Hilario. An overview of Strategies for Neurosymbolic Integration. In . *Connectionist Symbolic Integration . From Unified to Hybrid Approaches*. Ron Sun (ED.)- Chapter 2. Kluwer Academic Publishers. 1996.
- [3] J. Sima. Neural expert systems. *Neural networks*, Vol. 8, n°2. 1994.
- [4] R. Sun et F. Alexandre. *Connectionist-Symbolic Integration : From Unified to Hybrid Approaches.. Lawrence Erlbaum Associates. 1997.*
- [5] F. Mouria Beji et J. Boulahia Smirani. "Extraction and Insertion rules during the training process of a neural network". ACIDCA'2000. 22-24 March 2000, Monastir-Tunisia.
- [6] F. Mouria-Béji, J. Boulahia et M.Marrakchi. *ANREX : an algorithm for neural network rule extraction*. In IEEE International Multiconference on Computational Engineering in Systems Applications IEEE-SMC. April, 1998.
- [7] J. W. Shavlik, "Combining symbolic and neural learning". *Machine Learning*, vol. 14, n°3, pp. 321-331, 1994.
- [8] J. Boulahia-Smirani. *A new universal algorithm for neural rule extraction*. WSEAS Transactions on systems. Issue 2, Volume 3, avril 2004.
- [9] J. Boulahia-Smirani et F. Mouria-Beji. *A hybrid learning algorithm*. Brain Inspired Cognitive Systems. University of Stirling, Scotland. United Kingdom. Août 2004.
- [10] S. Hettich, C.L. Blake et C.J. Merz. UCI repository of machine learning databases [<http://www.ics.uci.edu/~mllearn/MLrepository.html>]. Irvine, CA, University of California. Department of Information and computer science. 1998.