

Apprentissage de Réseaux Bayésiens Causaux à partir de données d'observation et d'expérimentation

S. Meganck¹

S. Maes²

Ph. Leray²

¹ Vrije Universiteit Brussel, 1050 Brussels, Belgium

² INSA Rouen, 76801 St-Etienne du Rouvray Cedex, France

{smeganck, sammaes}@vub.ac.be
Philippe.Leray@insa-rouen.fr

Résumé

Les réseaux bayésiens proposés initialement par Pearl [3] comme des systèmes experts probabilistes sont maintenant un formalisme de plus en plus utilisé pour la modélisation de systèmes complexes ou le raisonnement lorsque les situations sont incertaines et/ou les données incomplètes.

Les réseaux bayésiens causaux [4] sont une extension des réseaux bayésiens classiques où toute relation entre variable correspond à une relation causale. Cette propriété fait que les réseaux bayésiens causaux sont des modèles graphiques probabilistes dont la structure est encore plus lisible par des experts du domaine considéré.

De nombreux algorithmes visent à déterminer la structure d'un réseau bayésien "classique" à partir de données [4, 5]. Nous abordons dans cet article le problème de l'apprentissage de la structure d'un réseau bayésien causal à partir de données puis d'expériences. Pour commencer, nous nous restreignons au cas des problèmes causalement suffisants, i.e. pour lesquels chaque cause commune à plusieurs variables mesurées est soit constante, soit mesurée elle aussi.

Les algorithmes d'apprentissage de structure basés sur des données d'observation, telles que les méthodes basées sur un score ou celles basées sur des tests d'indépendance conditionnelle permettent seulement de déterminer la structure du réseau bayésien à sa classe d'équivalence de Markov près (une autre structure de la même classe d'équivalence donnant le même score ou les mêmes indépendances conditionnelles). Dans une classe d'équivalence donnée, quelques arcs sont non dirigés alors que pour exploiter entièrement les possibilités offertes par un réseau bayésien causal, tous les arcs doivent être dirigés. Afin de trouver la structure complètement dirigée qui soit "causalement" correcte, des expériences spécifiques doivent être exécutées sur les variables reliées par des arcs non dirigés, en effectuant une action en dehors du système sur une des variables considérées et en mesurant les résultats de cette intervention sur d'autres variables.

Nous nous plaçons donc après l'exécution d'un algorithme classique d'apprentissage de structure d'un réseau bayésien à partir de données, et proposons la phase suivante, i.e. l'obtention du réseau bayésien causal correspondant à notre problème, en proposant une liste ordonnée d'expériences à effectuer en essayant de minimiser le

nombre total d'expériences et le coût correspondant. Quelques expériences peuvent potentiellement nous apporter davantage d'informations que d'autres, il est donc important de s'interroger sur la valeur de chaque expérience possible pour trouver un ordre d'exécution optimal.

Nous présentons une algorithmes qui mettent en application ces idées et qui tiennent compte également de la possibilité d'assigner des coûts hétérogènes à chaque expérience (et même de préciser qu'une expérience est impossible à exécuter). L'algorithme est adaptatif, et recherche à la vue des résultats des expériences passées quelle est l'expérience optimale suivante à exécuter utilisant le théorème de décision [2, 1].

Références

- [1] S. Meganck, P. Leray, and B. Manderick. Learning causal bayesian networks from observations and experiments : A decision theoretic approach. In *Modeling Decisions in Artificial Intelligence, LNCS*, 2006.
- [2] S. Meganck, S. Maes, P. Leray, and B. Manderick. Apprentissage des réseaux bayésiens causaux a partir de données d'observation et d'expérimentation. Accepted at the 15ième congrès francophone AFRIF-AFIA Reconnaissance des Formes et Intelligence Artificielle, 2006.
- [3] Judea Pearl. *Probabilistic Reasoning in Intelligent Systems*. Morgan Kaufmann, 1988.
- [4] Judea Pearl. *Causality : Models, Reasoning and Inference*. MIT Press, 2000.
- [5] P. Spirtes, C. Glymour, and R. Scheines. *Causation, Prediction and Search*. MIT Press, 2000.