



HAL
open science

Exploitation de la causalité pour l'apprentissage de règles floues

Lucie Kunitomo Jacquin, Aurore Lomet, Jean-Philippe Poli

► **To cite this version:**

Lucie Kunitomo Jacquin, Aurore Lomet, Jean-Philippe Poli. Exploitation de la causalité pour l'apprentissage de règles floues. LFA 2022 - Rencontres francophones sur la logique floue et ses applications, Oct 2022, Toulouse, France. pp.155. cea-04204949

HAL Id: cea-04204949

<https://cea.hal.science/cea-04204949>

Submitted on 12 Sep 2023

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.

Exploitation de la causalité pour l'apprentissage de règles floues

Causal discovery for fuzzy rule learning

Lucie Kunitomo-Jacquin

Aurore Lomet

Jean-Philippe Poli

Université Paris-Saclay, CEA, List, F-91120, Palaiseau, France

{prenom.nom}@cea.fr

Résumé :

Dans cet article, nous proposons une approche reliant la logique floue et la causalité afin de générer des connaissances et des explications à partir d'observations. L'idée est d'identifier les relations causales après fuzzification des entrées et des sorties en utilisant des algorithmes de recherche de causalité classiques tels que Peter-Clark et Fast Causal Inference. Nous combinons ces méthodes de recherche de causalité à des tests d'indépendance conditionnelle basés sur l'entropie pour s'affranchir d'hypothèses sur la distribution des données. Nous avons conduit des expérimentations pour évaluer la capacité de notre méthode à retrouver les relations causales dans différentes situations, notamment en présence d'une cause latente commune. Les résultats confirment l'intérêt de cette approche par rapport à des méthodes d'extraction de règles floues basées sur les corrélations et d'autres méthodes de l'état de l'art.

Mots-clés :

Règles floues, causalité imparfaite, recherche de causalité sous contraintes, entropie.

Abstract:

In this paper, we develop an approach that allies fuzzy logic and causality to generate knowledge from observations and to build explanations. The idea is to identify causal relationships on the set of fuzzified inputs and outputs by well-known constraints-based causal discovery algorithms such as Peter-Clark and Fast Causal Inference. The causal discovery algorithms are combined with entropy-based conditional independent testing that avoids making hypotheses on the data distribution. Experiments are conducted to evaluate our approach in terms of ability to recover causal relationships between fuzzy sets in the presence of a latent common cause. The results illustrate the interest of our approach compared to a correlation-based approach and state-of-the-art approaches.

Keywords:

Fuzzy rules, imperfect causality, constraint-based causal discovery, entropy.

1 Introduction

Les algorithmes d'induction de règles floues sont généralement basés sur des critères statistiques comme la corrélation. Malgré leurs performances en termes de prédiction, la prise en

compte d'un modèle causal de la réalité [12] est nécessaire pour approcher les performances humaines. En effet, le raisonnement causal est une caractéristique essentielle de notre compréhension du monde. Par ailleurs, la logique floue permet de représenter et manipuler des connaissances sous une forme proche du langage naturel. Ainsi, une représentation floue des mécanismes causaux serait un atout pour l'extraction de connaissances interprétables. Nos travaux visent à construire, à partir d'un jeu de données, des *règles floues causales*, au sens où les prémisses floues sont les causes de leurs conclusions floues associées. De telles règles pourraient être utiles dans de nombreux domaines scientifiques nécessitant, non seulement une tâche de prédiction mais aussi une représentation pertinente et compréhensible des informations extraites du jeu de données. Par exemple, en science des matériaux, pour identifier les liens causaux entre les paramètres de fabrication et les propriétés des matériaux, nous souhaiterions générer des règles telles que « la faible viscosité d'un liquide *cause* une température basse du liquide » à partir de données expérimentales comprenant entre autres une mesure de la viscosité et de la température.

2 Travaux antérieurs

2.1 Recherche de causalité classique

Les modèles causaux structuraux constituent un des cadres les plus utilisés pour décrire les mécanismes causaux [11]. Ils définissent à la

fois des équations structurelles, qui spécifient les effets causaux de chaque variable, et un graphe causal, qui correspond à une interprétation causale d'un réseau Bayésien [6]. Le graphe causal respecte la condition causale de Markov, c'est-à-dire que toute variable est indépendante de tous ses non-descendants causaux conditionnellement à l'ensemble de ses causes directes. Plus formellement, considérons un graphe causal dirigé acyclique $G = (\mathcal{V}, \mathcal{E})$, où \mathcal{V} est l'ensemble des nœuds (i.e. des variables) et \mathcal{E} l'ensemble des arêtes représentant les liens causaux entre ces variables. Un nœud C bloque un chemin z conditionnellement à un ensemble de nœuds S , si l'une des conditions suivantes est vérifiée [6] : i) $C \in S$ et C est une chaîne $A \rightarrow C \rightarrow B$ ou une fourche $A \leftarrow C \rightarrow B$; ii) $C \notin S$, aucun descendant de C n'est dans S et z est une fourche inversée $A \rightarrow C \leftarrow B$. Deux nœuds X et Y de \mathcal{E} sont dits d -séparés dans G par un sous-ensemble S de \mathcal{E} si tous les chemins entre X et Y sont bloqués conditionnellement à S .

Dans cet article, nous nous concentrons sur la tâche de recherche de causalité qui consiste à estimer le graphe causal à partir d'observations. Le sujet est abondamment traité dans la littérature [6]. On peut distinguer trois principales familles d'approches : celles basées sur un score (SB) [2], qui recherchent les graphes permettant d'approcher au mieux la distribution des données en utilisant un score tel que le Bayesian Information Criterion; les méthodes dites fonctionnelles (FCM) [14], qui visent à déterminer l'orientation des arêtes dans leur processus en faisant l'hypothèse que les bruits des effets devraient être indépendants des causes. Et enfin celles basées sur des contraintes (CB) qui exploitent les relations d'indépendance conditionnelle. Ces dernières méthodes utilisent la réciproque de la condition de Markov : si $X \perp\!\!\!\perp Y | S$, i.e., X et Y sont indépendants sachant S , alors X et Y sont d -séparés par S dans le graphe G . La condition de Markov et sa réciproque assurent une correspondance entre les d -séparations dans

le graphe et les indépendances conditionnelles dans les données. Parmi les algorithmes de recherche de causalité sous contraintes figurent les bien connus algorithmes de Peter-Clark (PC) [15] et Fast Causal Inference (FCI) [3]. L'algorithme PC a été conçu pour estimer une classe d'équivalence de Markov sur des graphes dirigés acycliques, en faisant l'hypothèse selon laquelle aucune cause commune non mesurée ni variable de sélection ne sont présentes. La première étape de PC consiste à estimer le squelette de graphe, c-à-d un graphe non orienté. Pour cela, l'algorithme commence avec un graphe totalement connecté et élimine successivement toutes les arêtes qui correspondent à des d -séparations en pratiquant une série de tests d'indépendance conditionnelle. Contrairement à l'algorithme PC, FCI permet de prendre en compte les variables latentes en estimant une classe spéciale d'équivalence de Markov, appelée graphe ancestral partiel.

2.2 Causalité imparfaite

Dans le langage naturel, les liens causaux sont souvent exprimés en des termes vagues. L'imperfection peut concerner les définitions des causes et des effets, comme par exemple dans « dormir moins cause une fatigue inhabituelle ». Elle peut concerner également le lien causal lui-même, comme dans « dormir moins peut causer une fatigue inhabituelle ». Dans cet article, nous nous concentrons sur la recherche de causalité sans chercher à qualifier les liens. Ainsi nous considérons uniquement les imperfections entachant les définitions des causes et des effets. Les méthodes de recherche de causalité classiques introduites précédemment ne sont pas adaptées à la prise en compte de telles imperfections. En effet, si les nœuds ont une sémantique vague, les distributions ne peuvent pas être spécifiées de manière exacte. Pour pallier ce problème, différentes alternatives ont été proposées. Les cartes cognitives de Kosko permettent de prendre en compte la causalité imparfaite dans des systèmes dynamiques, c'est-à-dire autorisant des cycles. Cependant, dans

notre travail, nous considérons uniquement des graphes acycliques car les causes sont toujours les entrées et les effets, les sorties de notre système. Une méthode alternative développée dans [4] consiste à formaliser les liens causaux en s'appuyant sur une couverture parcimonieuse des effets. Pour cela, les auteurs introduisent un modèle spécifique et une méthode qui définit les liens possibles entre causes et effets sans garantir leur nécessité. Cependant, cette approche ne répond pas exactement à notre objectif de détecter la présence de liens causaux entre des sous-ensembles flous. Avant la théorie de la couverture parcimonieuse, Sanchez [13] avait proposé des méthodes relationnelles floues dans le domaine du diagnostic pour représenter l'intensité des symptômes et des troubles. Ces travaux sont plus proches de ce que nous souhaitons accomplir. Cependant, ils supposent que les symptômes sont indépendants [5], hypothèse que nous ne pouvons pas nous permettre. Plus récemment, des travaux se sont intéressés à la formulation d'explication contrastives floues [1, 18].

3 Positionnement du problème et motivation

Supposons que nous disposons d'un ensemble d'observations précises de variables d'entrée et de sortie. A partir de ces données, nous cherchons à générer des connaissances causales imparfaites sous la forme d'une liste de relations causales entre les modalités des variables linguistiques attribuées à chaque entrée et à chaque sortie. Plus formellement, dénotons les variables d'entrée et de sortie X_1, \dots, X_p , $p > 0$. Pour chaque variable aléatoire initiale X_i , notons $A_i^1, \dots, A_i^{m_i}$, $m_i > 2$, les différentes modalités (sous-ensembles flous). Nous définissons ensuite une nouvelle variable aléatoire pour chaque sous-ensemble flou A_i^j , décrivant les valeurs d'appartenance à ce sous-ensemble flou : $Z_i^j = \mu_{A_i^j}(X_i)$, $j = 1, \dots, m_i$ et $i = 1, \dots, p$, où $\mu_{A_i^j}$ est la fonction d'appartenance de A_i^j . Notons que l'espérance




FIGURE 1 – Définition d'une nouvelle variable.

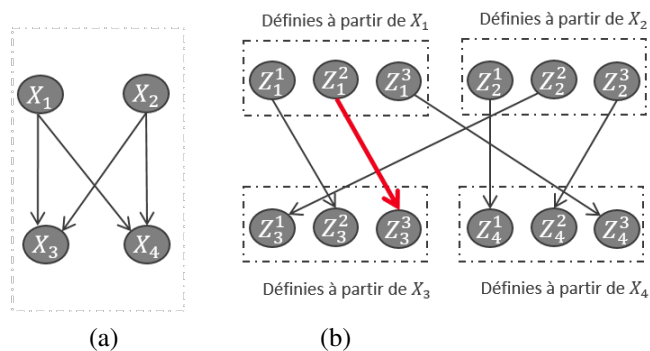


FIGURE 2 – Graphes causaux avec les variables initiales (a), les nouvelles variables (b).

de Z_i^j correspond à la probabilité (non floue) de l'évènement flou A_i^j au sens de Zadeh [16].

Notre problème consiste à identifier les relations causales entre les variables aléatoires $\{Z_i^j\}_{j=1, \dots, m_i, i=1, \dots, p}$.

En comparaison avec les approches classiques de recherche de causalité, identifier de telles relations causales permet de raffiner les affirmations causales tout en restant fortement intelligible. Illustrons cet intérêt avec un exemple fictif dans le domaine des matériaux et des procédés. Dans cet exemple, différentes réalisations sont observées pour les 4 variables aléatoires suivantes : $X_1 :=$ « Température de fabrication », $X_2 :=$ « Pression de fabrication », $X_3 :=$ « Résistance du matériau » et $X_4 :=$ « Allongement à la rupture ». La Figure 1 illustre l'introduction des nouvelles variables aléatoires Z_1^2 dans notre exemple. Elle montre qu'avec une observation x_1 de la variable aléatoire X_1 (température), il est possible d'obtenir une observation z_1^2 de la variable aléatoire Z_1^2 (appartenance de la température à la modalité « proche de 0 »). Le graphe causal de la Figure 2a est un exemple de résultat

que l'on pourrait obtenir en appliquant une méthode de recherche de causalité classique sur les variables aléatoires initiales. Dans ce graphe, les paramètres de fabrication X_1 et X_2 pointent sur les propriétés du matériau X_3 et X_4 . Cette représentation ne nous informe pas sur les valeurs des paramètres et des propriétés qui sont impliquées dans ces relations causales. En revanche, avec un graphe causal flou, comme présenté dans la Figure 2b, défini sur les nouvelles variables aléatoires, il serait possible d'extraire davantage d'informations sur la structure causale sous-jacente. Par exemple, l'arête en gras colorée indique que la valeur d'appartenance de la température (X_1) au sous-ensemble flou $A_1^2 = \ll \text{proche de } 0 \gg$ a un effet causal direct sur la valeur d'appartenance de la résistance (X_3) au sous-ensemble flou $A_3^3 = \ll \text{important} \gg$. L'information causale extraite peut ainsi être formulée par « une température proche de 0 a un effet causal direct sur le fait d'avoir une résistance importante ». Elle est ainsi raffinée, tout en restant intelligible, comparée à l'information que l'on aurait obtenue avec les méthodes classiques, à savoir « la température a un effet causal sur la résistance ». En supposant qu'un tel énoncé causal imparfait soit trouvé, nous proposons de le traduire par une règle floue dans laquelle la cause imparfaite prend le rôle d'une prémisse floue et l'effet imparfait se traduit par une conséquence floue positive ou négative selon le signe de la corrélation entre la cause et l'effet. Revenant à l'exemple précédent et supposant une corrélation positive entre « température proche de 0 » et « résistance importante ». Nous pouvons alors formuler la règle floue suivante : « Si la température est proche de 0 alors la résistance est importante ». Ainsi, répondre au problème posé peut servir à induire des règles floues causales à partir d'un jeu de données. De telles règles floues basées sur la causalité peuvent être utilisées non seulement pour la prédiction, mais également pour fournir des informations sur le mécanisme qui relie les entrées et les sorties contrairement au cas des règles floues classiquement basées sur

la corrélation. En effet, les corrélations peuvent être dues à une cause commune latente : ainsi, agir sur la prémisse n'aura aucun impact sur la conséquence. Dans l'exemple précédent, les variables latentes peuvent être le type et les paramètres du dispositif de fabrication utilisé, les caractéristiques de l'environnement ou la conception du plan expérimental.

4 Approche proposée

Nous proposons d'adapter un algorithme de recherche de causalité pour le cas de variables aléatoires représentant des appartenances à des sous-ensembles flous, dénotées précédemment $\{Z_i^j\}_{j=1,\dots,m_i, i=1,\dots,p}$. Nous ne nous préoccupons ici de l'origine de ces sous-ensembles flous qui peuvent être définis par des experts, fixés de manière uniforme ou encore extraits automatiquement. Pour chercher des relations causales entre ces nouvelles variables, il est nécessaire de considérer quelques particularités. D'abord, ces nouvelles variables ne suivent pas de distributions connues. De plus, nous ne pouvons faire aucune hypothèse sur le type de relation fonctionnelle entre les causes et les effets. À cela s'ajoute que les nouvelles variables ne sont pas toutes sémantiquement indépendantes, bien que cela soit requis par les algorithmes de recherche de causalité [9]. Enfin, une hypothèse simplificatrice concernant les entrées et les sorties est fixée : les modalités des variables linguistiques des entrées (resp. des sorties) constituent l'ensemble des causes (resp. des effets) possibles. Ainsi, l'orientation des arêtes dans le graphe causal est donnée.

Notre approche s'inscrit dans la famille des algorithmes de recherche de causalité sous contraintes. En effet, les FCM nécessiteraient de faire des hypothèses sur les liens fonctionnels entre les variables et les SB ne sont pas conçues pour prendre en compte des variables latentes. Ainsi, nous partons des deux algorithmes introduits précédemment, PC et FCI. Pour tester l'indépendance conditionnelle, nous pourrions utiliser le test appelé Kernel-

based Conditional Independence [17], conçu pour ne faire aucune hypothèse sur la distribution des variables, ni sur les relations fonctionnelles entre elles. Cependant, ce test nécessite une adéquation entre le noyau choisi et la distribution de l'échantillon. Afin de pallier ce problème, nous intégrons une procédure basée sur le critère Stochastic complexity-based Conditional Independence (SCI) [10] qui utilise l'information mutuelle conditionnelle comme une mesure de l'indépendance conditionnelle : si l'information mutuelle de X et Y , conditionnellement à Z , est nulle, i.e., $I(X; Y|Z) := H(X|Z) - H(X|Z, Y) = 0$, où $H(\cdot)$ est la fonction de l'entropie de Shannon, alors les deux variables X et Y sont statistiquement indépendantes conditionnellement à Z . Les auteurs proposent une approximation de l'information mutuelle conditionnelle qui repose sur la complexité stochastique [10]. Puisque cette procédure est conçue pour des données discrètes, les observations des nouvelles variables sont discrétisées.

Par ailleurs, un phénomène de redondance pure se produit si deux variables sont mathématiquement inter-définissables [9]. Dans notre cas, ce phénomène se produirait si pour deux sous-ensembles flous A et B , $\forall x$, $\mu_A(x) = 1 - \mu_B(x)$. Ce cas est simplement évité en choisissant un nombre de termes strictement supérieur à 2 pour chaque variable linguistique. Cependant, par construction, des dépendances sémantiques subsistent entre chaque terme d'une même variable linguistique. De ce fait et pour faciliter la recherche des liens causaux par les algorithmes PC et FCI, nous ajoutons la contrainte selon laquelle aucune relation causale n'est possible entre les termes extraits d'une même variable. Pour garantir cela, nous supprimons les arêtes non autorisées avant de lancer la recherche de causalité. De la même façon, l'information contextuelle est prise en compte en supprimant des arêtes non autorisées. Finalement l'orientation des arêtes est choisie dans la direction des entrées vers les sorties.

La complexité de notre approche dépend de celle de l'algorithme de recherche de causalité sous-jacent. Dans le cas de l'algorithme PC, la complexité est en $O(\nu n)$, avec $\nu = \max(p^q, p^2)$ où q est le nombre maximal de voisins pour un nœud [8]. Dans notre version floue de l'algorithme PC, les p variables initiales sont remplacées par les nouvelles variables $\{Z_i^j\}_{j=1, \dots, m_i, i=1, \dots, p}$, ce qui augmente la complexité. Cependant, la complexité diminue également avec la suppression des arêtes entre les termes d'une même variable linguistique et les arêtes non autorisées.

5 Application à l'induction de règles floues

5.1 Protocole des simulations

Les simulations sont conçues pour évaluer la capacité à retrouver un graphe causal flou. Les différentes approches testées recevront en entrée des valeurs d'appartenance à des ensembles flous simulées à partir du graphe causal flou à retrouver. Les graphes causaux flous servant de vérité terrain sont construits selon le même modèle : 4 variables initiales non floues, parmi lesquelles deux entrées X_1, X_2 et deux sorties X_3, X_4 . Pour chaque variable initiale, une variable linguistique à 3 termes est créée. On obtient ainsi 12 nouvelles variables $\{Z_i^j\}_{j=1,2,3, i=1,2,3,4}$ décrivant les valeurs d'appartenance aux 12 sous-ensembles flous. Les arêtes sont choisies aléatoirement pour correspondre à une liste de règles floues telle que chaque terme de chaque variable linguistique soit utilisée au moins une fois afin de d'assurer une couverture représentative des données. La construction de la base de règles est effectuée par une bijection entre les termes des variables linguistiques des entrées et ceux des sorties. Le graphe causal représenté sur la Figure 2b est un exemple de graphe généré par cette technique. Une fois la base de règles générée, il nous faut générer des réalisations pour les variables $\{Z_i^j\}_{j=1,2,3, i=1,2,3,4}$. Deux hypothèses de simulation sont considérées : avec une variable

latente commune à X_1 et X_2 , notée H ($X_1 \not\perp\!\!\!\perp X_2$ mais $X_1 \perp\!\!\!\perp X_2 | H$), et sans variable latente. Dans ce dernier cas, n observations de X_1 et X_2 sont générées selon une distribution normale : $X_1 \sim \mathcal{N}(0, 1)$ et $X_2 \sim \mathcal{N}(0, 1)$. Dans le premier cas, nous générerons n observations de X_1 et X_2 où $X_1 \sim \mathcal{N}(0, 1) + H$ et $X_2 \sim \mathcal{N}(0, 1) + H$ avec $H \sim \mathcal{N}(0, 1)$. Une fois les n observations des entrées générées, nous créons les variables linguistiques associées à l'aide de partitions fortes de leurs univers. Pour chaque variable initiale d'entrée, 3 fonctions d'appartenance triangulaires et semi-triangulaires aux extrémités sont créées. Nous faisons de même avec les sorties que nous calculons ensuite à l'aide de la base de règles. Nous utilisons un système de Mamdani choisi avec le maximum pour l'agrégation et le centroïde pour la défuzzification. Les méthodes testées sont résumées ci-dessous :

- *fuzzy pc SCI et fuzzy fci SCI*. Il s'agit des approches que nous proposons. Les algorithmes PC et SCI sont exécutés en utilisant le critère SCI [10], après discrétisation des valeurs d'appartenance de sorte à obtenir 20 catégories à fréquence égale.
- *fuzzy pc gauss et fuzzy fci gauss*. PC et FCI sont exécutés avec le test d'indépendance conditionnelle basé sur la z -transformation de Fischer des corrélations partielles [7].
- *fuzzy pc KCI et fuzzy fci KCI*. PC et FCI sont exécutés avec le critère du Kernel-based Conditional Independence test [17].
- *corr τ* . Les arêtes autorisées entre des nœuds dont la corrélation est supérieure à un seuil τ sont ajoutées. Puisque les distributions sont inconnues, les corrélations sont évaluées par le coefficient de Kendall.
- *random*. Chaque arête autorisée est ajoutée avec une probabilité de 0.5.

Les performances de ces approches sont évaluées en termes de précision (pourcentage d'arêtes qui sont correctes) et de rappel (pourcentage de vraies arêtes retrouvées).

5.2 Influence d'une variable latente

La Figure 3 présente les scores moyens de précision et de rappel obtenus sur 500 simulations avec $n = 300$ observations pour chacune des approches *fuzzy pc SCI*, *fuzzy fci SCI*, *fuzzy pc gauss*, *fuzzy fci gauss*, *corr τ* , avec τ variant entre $[0, 1]$, et *random*. Les quelques simulations ($\leq 0.3\%$) sur lesquelles les approches ont échoué à estimer un graphe causal ont été retirées des résultats (il s'agit en général de cas où l'une des variables est trop proche d'une constante).

L'approche *random* atteint la précision et le rappel espérés. En effet, puisque chaque arête a une probabilité de 0.5 d'être ajoutée et qu'il y a toujours 6 arêtes dans le graphe simulé à trouver parmi 36 arêtes possibles, la précision espérée est de $1/6$ et le rappel espéré est de $1/2$.

Les performances de l'approche *corr τ* varient en fonction du τ choisi. Les meilleures précisions sont atteintes pour τ autour de 0.6. Quand τ excède 0.7, la précision et le rappel diminuent. En effet, conserver uniquement les arêtes associées à une très forte corrélation revient à en conserver de moins en moins. De l'autre côté, plus τ est faible, plus la précision baisse, tandis que le rappel tend vers 1. En effet, quand τ est diminuée, le nombre d'arêtes ajoutées augmente, jusqu'à l'obtention d'un graphe totalement connecté (6×6 arêtes) pour $\tau = 0$. Dans ce cas extrême, toutes les arêtes sont nécessairement retrouvées donc le rappel est maximal. En revanche, sur les 6×6 arêtes trouvées, seules 6 seront correctes, forçant la précision à valoir $1/6$. En introduisant la variable latente H , on observe une nette chute de la précision et une légère diminution du rappel.

A présent, intéressons nous aux approches réellement conçues pour la causalité, à savoir *fuzzy pc gauss*, *fuzzy fci gauss*, et nos approches *fuzzy pc SCI* et *fuzzy fci SCI*. On observe qu'en présence de la variable latente, ces méthodes parviennent mieux à maintenir leurs performances en termes de précision et de rappel. Notons que les approches *fuzzy pc gauss* et *fuzzy fci gauss* ne sont

pas compétitives avec les méthodes basées sur la corrélation à cause du test d'indépendance conditionnelle utilisé (z -transformation de Fischer sur la corrélation partielle) qui fait l'hypothèse de distributions Gaussiennes, ce qui n'est pas le cas de nos données simulées. Finalement, seules nos approches *fuzzy pc SCI* et *fuzzy fci SCI* atteignent des précisions supérieures à 0.6.

○ fuzzy pc gauss ● fuzzy pc SCI 20 + corr τ
 △ fuzzy fci gauss ▲ fuzzy fci SCI 20 * random

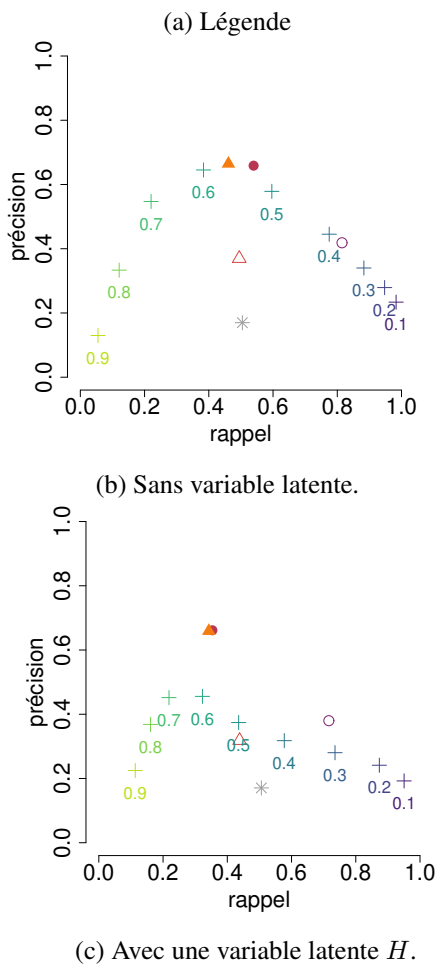


FIGURE 3 – Pour les approches présentées en (3a), précision moyenne contre rappel moyen, sans variable latente (3b) et avec (3c).

5.3 Influence du nombre d'observations

Les scores moyens de précision et de rappel en fonction du nombre n d'observations sont présentés dans la Figure 4. Précisons que les ap-

proches *fuzzy pc KCI* et *fuzzy fci KCI* n'ont été testées que pour $n = 100$ à cause de leurs temps d'exécution. Comme précédemment, quelques simulations ont dû être écartées : quel que soit le n choisi, cela concernait moins de 3% des simulations. On observe que les méthodes basées sur les corrélations restent plutôt stables en termes de précision et de rappel. Les approches *fuzzy pc gauss*, *fuzzy fci gauss* perdent en précision lorsque n augmente. Pour $n = 100$, les approches *fuzzy pc KCI* et *fuzzy fci KCI* sont moins performantes en termes de précision et de rappel que nos approches. Cela est dû au fait que le noyau Gaussien n'est pas adapté aux données simulées. D'autre part, les approches proposées gagnent en précision jusqu'à 300 observations, puis restent stables. En termes de rappel, nos approches sont peu sensibles aux variations de n .

6 Conclusion

Cet article propose un cadre innovant pour représenter des énoncés causaux dans lesquels les définitions des causes et des effets sont exprimées par des ensembles flous. Il est ensuite possible d'obtenir des règles floues causales. Contrairement aux règles floues standard, ces règles ne sont pas uniquement conçues pour la prédiction, mais permettent également une meilleure compréhension des phénomènes observés. Nous avons proposé une adaptation d'algorithmes classiques de recherche de causalité dont les hypothèses ne permettaient pas d'être appliqués directement à des sous-ensembles flous. Les résultats obtenus sur des données simulées démontrent les bonnes capacités de notre approche pour retrouver la structure causale sous-jacente, en particulier en présence d'une variable latente.

Notre première perspective est d'appliquer nos algorithmes à des données réelles en collaboration avec des experts pour valider les liens causaux trouvés. Ensuite, nous nous intéresserons à l'extraction automatique et optimisée des variables linguistiques. Enfin, nous envisageons

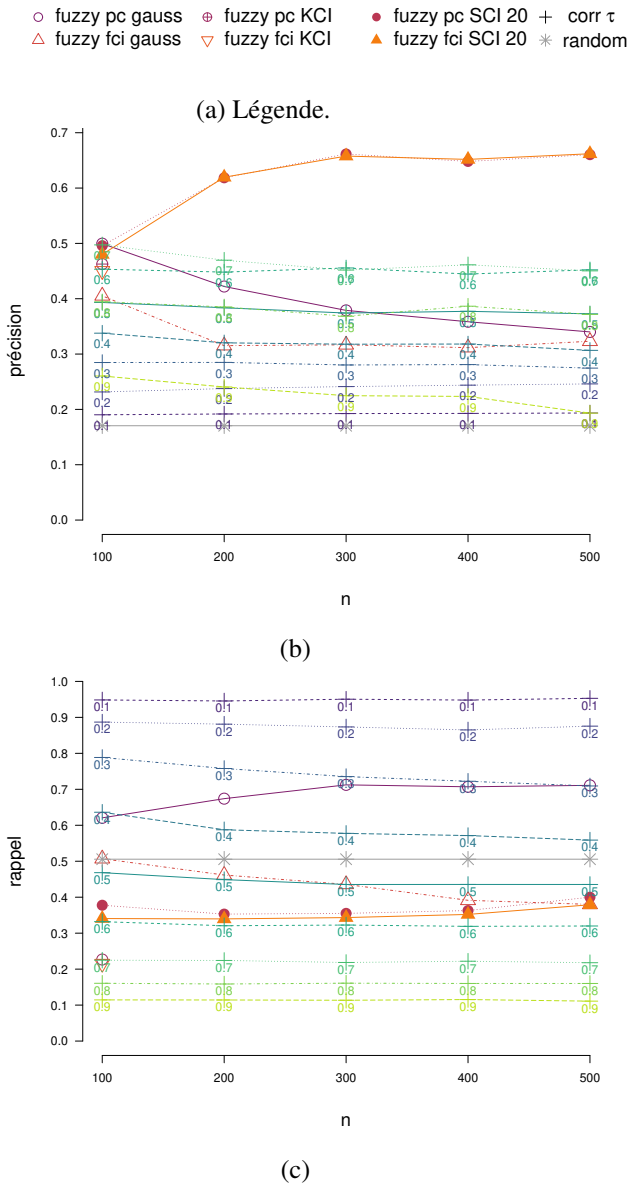


FIGURE 4 – Pour les approches présentées en (4a), précisions moyennes 4b et rappels moyens 4c en fonction du nombre d’observations n .

de généraliser ces travaux à des règles plus complexes et discriminantes (disjonctions et conjonctions).

Remerciements :

Ces travaux ont été financés par le plan transverse de compétences en matériaux et procédés du CEA.

Références

[1] Isabelle Bloch and Marie-Jeanne Lesot. Towards a formulation of fuzzy contrastive explanations. In *2022 IEEE International Conference on Fuzzy Sys-*

tems (FUZZ-IEEE). IEEE, 2022.

[2] David Maxwell Chickering. Optimal structure identification with greedy search. *Journal of machine learning research*, 3(Nov) :507–554, 2002.

[3] Diego Colombo, Marloes H Maathuis, Markus Kalisch, and Thomas S Richardson. Learning high-dimensional directed acyclic graphs with latent and selection variables. *The Annals of Statistics*, pages 294–321, 2012.

[4] Didier Dubois and Henri Prade. Fuzzy relation equations and causal reasoning. *Fuzzy sets and systems*, 75(2) :119–134, 1995.

[5] Didier Dubois and Henri Prade. An overview of ordinal and numerical approaches to causal diagnostic problem solving. *Abductive reasoning and learning*, pages 231–280, 2000.

[6] Ruocheng Guo, Lu Cheng, Jundong Li, P Richard Hahn, and Huan Liu. A survey of learning causality with data : Problems and methods. *ACM Computing Surveys (CSUR)*, 53(4) :1–37, 2020.

[7] Markus Kalisch and Peter Bühlman. Estimating high-dimensional directed acyclic graphs with the pc-algorithm. *Journal of Machine Learning Research*, 8(3), 2007.

[8] Markus Kalisch and Peter Bühlmann. Robustification of the pc-algorithm for directed acyclic graphs. *Journal of Computational and Graphical Statistics*, 17(4) :773–789, 2008.

[9] Daniel Malinsky and David Danks. Causal discovery algorithms : A practical guide. *Philosophy Compass*, 13(1), 2018.

[10] Alexander Marx and Jilles Vreeken. Testing conditional independence on discrete data using stochastic complexity. In *The 22nd International Conference on Artificial Intelligence and Statistics*, pages 496–505. PMLR, 2019.

[11] Judea Pearl. *Causality*. Cambridge university press, 2009.

[12] Judea Pearl. Theoretical impediments to machine learning with seven sparks from the causal revolution. *arXiv preprint arXiv :1801.04016*, 2018.

[13] Elie Sanchez. Solutions in composite fuzzy relation equations : application to medical diagnosis in brouwerian logic. In *Readings in Fuzzy Sets for Intelligent Systems*, pages 159–165. Elsevier, 1993.

[14] Shohei Shimizu, Patrik O Hoyer, Aapo Hyvärinen, Antti Kerminen, and Michael Jordan. A linear non-gaussian acyclic model for causal discovery. *Journal of Machine Learning Research*, 7(10), 2006.

[15] Peter Spirtes, Clark N Glymour, Richard Scheines, and David Heckerman. *Causation, prediction, and search*. MIT press, 2000.

[16] Lotfi Asker Zadeh. Probability measures of fuzzy events. *Journal of mathematical analysis and applications*, 23(2) :421–427, 1968.

[17] Kun Zhang, Jonas Peters, Dominik Janzing, and Bernhard Schölkopf. Kernel-based conditional independence test and application in causal discovery. *arXiv preprint arXiv :1202.3775*, 2012.

[18] Te Zhang, Christian Wagner, and Jonathan M. Garibaldi. Counterfactual rule generation for fuzzy rule-based classification systems. In *2022 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*. IEEE, 2022.