
Sharp Bounds for Continuous-Valued Treatment Effects with Unobserved Confounders

Jean-Baptiste Baitairian^{*1,2}, Bernard Sebastien¹, Rana Jreich¹, Sandrine Katsahian^{2,3},
and Agathe Guilloux²

¹Sanofi-Aventis RD – SANOFI Recherche et Développement – France

²Health data- and model- driven Knowledge Acquisition (HeKA) – Institut National de la Santé et de la Recherche Médicale - INSERM, Université Paris-Cité, Institut National de Recherche en Informatique et en Automatique – France

³CIC1418 - HEGP – Hôpital Européen Georges Pompidou [APHP], Institut National de la Santé et de la Recherche Médicale - INSERM – France

Résumé

L'estimation d'effets liés à des expositions ou à des traitements continus (plus généralement, à des interventions continues) à partir de données observationnelles, aussi appelées données vie réelle, est cruciale dans des domaines comme les sciences de la vie ou l'économie. Comprendre l'impact de la concentration d'un polluant dans l'air sur le taux de mortalité ou encore le lien entre la quantité d'un biomarqueur dans le plasma sanguin et l'évolution de la taille d'une tumeur sont des exemples d'applications d'intérêt. Dans le domaine de l'inférence causale, l'estimation d'effets de traitements continus est habituellement effectuée sous hypothèse d'unconfoundedness, ou ignorability (Rubin, 1974). Elle suppose que l'ensemble des variables confondantes, c'est-à-dire des variables qui ont un effet à la fois sur le traitement et la réponse, aient été observées et que, au sein d'un groupe d'individus partageant des variables similaires, le traitement ait été alloué de manière totalement aléatoire. Par exemple, dans le cas de traitements continus, Kallus et Zhou (2018) ont proposé un estimateur à noyau de l'APO (Average Potential Outcome) sous cette hypothèse. Cependant, dans le cas de données observationnelles, l'hypothèse d'unconfoundedness est souvent irréaliste et impossible à vérifier. Des travaux récents sur les traitements binaires suggèrent donc de s'éloigner de cette hypothèse à l'aide de modèles de sensibilité (Rosenbaum, 2002 ; Tan, 2006 ; Zhao, Small et Bhattacharya, 2019 ; Dorn et Guo, 2022 ; Yadlowsky et al., 2022 ; Dorn, Guo et Kallus, 2024), le but devenant alors de borner le véritable APO et d'en déduire des intervalles de confiance. S'appuyant sur ces travaux, Jesson et al. (2022) ont récemment étendu au cas continu le Modèle Marginal de Sensibilité de Tan (2006). En se basant sur l'estimateur doublement robuste de l'APO de Kallus et Zhou (2018), nous présentons une nouvelle approche permettant d'obtenir des bornes optimales, c'est-à-dire les plus étroites possibles, en particulier, plus étroites que celles proposées par Jesson et al. (2022). En pratique, nous confirmons ce résultat sur des jeux de données simulés et réels et montrons aussi qu'il est possible d'obtenir des temps d'exécution dont l'ordre de grandeur est nettement plus faible qu'avec la méthode concurrente.

Dorn, Jacob et Kevin Guo (2022). " Sharp sensitivity analysis for inverse propensity weighting via quantile balancing ". In : Journal of the American Statistical Association, p. 1-13.

*Intervenant

Dorn, Jacob, Kevin Guo et Nathan Kallus (2024). "Doubly-valid/doubly-sharp sensitivity analysis for causal inference with unmeasured confounding". In : Journal of the American Statistical Association just-accepted, p. 1-23.

Jesson, Andrew et al. (2022). "Scalable sensitivity and uncertainty analyses for causal-effect estimates of continuous-valued interventions". In : Advances in Neural Information Processing Systems 35, p. 13892-13907.

Kallus, Nathan et Angela Zhou (2018). "Policy evaluation and optimization with continuous treatments". In : International conference on artificial intelligence and statistics. PMLR, p. 1243-1251.

Rosenbaum, P.R. (2002). *Observational Studies*. Springer Series in Statistics. Springer. ISBN : 9780387989679. URL : <https://books.google.fr/books?id=K0OglGXtpGMC>.

Rubin, Donald B (1974). "Estimating causal effects of treatments in randomized and non-randomized studies". In : Journal of educational Psychology 66.5, p. 688.

Tan, Zhiqiang (2006). "A distributional approach for causal inference using propensity scores". In : Journal of the American Statistical Association 101.476, p. 1619-1637.

Yadlowsky, Steve et al. (2022). "Bounds on the conditional and average treatment effect with unobserved confounding factors". In : The Annals of Statistics 50.5, p. 2587-2615.
Zhao, Qingyuan, Dylan S Small et Bhaswar B Bhattacharya (2019). "Sensitivity analysis for inverse probability weighting estimators via the percentile bootstrap". In : Journal of the Royal Statistical Society Series B : Statistical Methodology 81.4, p. 735-761.