

異なる世界間の比較に基づく統計的因果推論



研究ノート

山本 倫生*

Statistical causal inference through comparisons across different worlds

Key Words : Causal inference, Counterfactual, Potential outcome, Structural causal model

はじめに

事象間の因果関係を解明することはあらゆる科学分野における目的の1つであろう。たとえば、医学研究ではある疾患における新規治療法が疾患を改善させるかどうかを評価するが、これは新規治療法(原因)と疾患の改善(結果)の因果関係を検討している。同様に、心理学研究において、ある尺度で測定される心理量が抑うつ症状の程度を低下させるかどうかを評価する場合には、心理量(原因)と抑うつ症状の程度(結果)の因果関係を解明することが目的となる。

一般に、データに基づいて統計学的に因果関係について推論を行うことを統計的因果推論とよぶ。統計的因果推論における因果効果の定義を理解するために、例を考えてみよう。いま、あなたが腹痛になったことを想像してみしてほしい。あまりの痛みに耐えられなくなり胃腸薬を飲んだところ、腹痛がすっかり治まったとしよう。そのとき、胃腸薬のおかげで腹痛が治まった、つまり、胃腸薬の効果があったと解釈できるかもしれないが、それは本当に正しいのだろうか。たとえば、現実とは異なり、胃腸薬を飲まずに安静にしていた場合に、もしかすると腹痛は治っていたかもしれない(図1)。その場合、胃腸薬の服用のいかんにかかわらず腹痛は治ってしまうため、胃腸薬の効果は特になかったと考えられる。

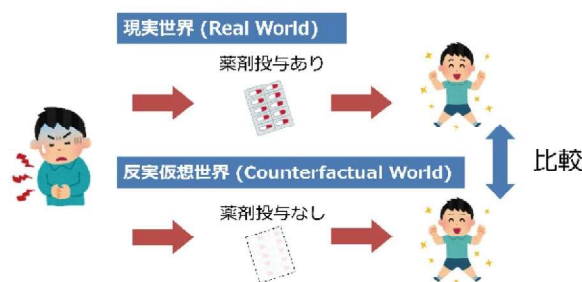


図1. 反実仮想と因果効果の関係。因果効果は現実とは異なる状態との比較によって定義される。

このように、統計的因果推論ではある個人に対する薬の因果効果を、薬を飲んだ場合(実際の状態)と飲まなかった場合(事実と異なる反事実の状態)とを比較することで定義する。しかし、両方の場合を同時に観測することはできないため、現実には個人に対する因果効果を推定することは不可能である。このことを因果推論の根本問題ということもある[2]。そこで、統計的因果推論では個人に対する因果効果ではなく、集団に対する因果効果を定義し、データから推定する問題を考える。本稿では、統計的因果推論における因果効果を検討するための主なフレームワークとして、ルービン因果モデルと構造的因果モデルを紹介しよう。また、これらのフレームワークを利用した関連の研究についても紹介する。

統計的因果推論の2つのフレームワーク

ある処理変数(実験条件や治療を表す変数)について2つの水準があるとしよう。ルービン因果モデル(もしくはネイマン・ルービン因果モデル)では、ある処理変数 A の水準 a を割り付けた場合に観測されるであろう結果変数を表す記号 $Y_{A=a}$ (もしくは Y_a) を導入する。これを潜在結果変数という。潜在結果変数の導入により、現実とは異なる処理の水準での値は観測できず欠測となっていると考えられ、前述の因果推論の根本問題を欠測データの問題と捉



* Michio YAMAMOTO

1983年5月生まれ
大阪大学 大学院基礎工学研究科 システム創成専攻 博士後期課程 (2013年修了)
現在、大阪大学 大学院人間科学研究科 准教授 博士(理学)
専門/計量心理学、医学統計学、多変量解析
TEL : 06-6879-4040
E-mail : yamamoto.michio.hus@osaka-u.ac.jp

表 1. 潜在結果変数と観測データとの関係. 網掛け部分は実際には観測されず欠測と考えられる.

群	処理の水準「1」を受ける群				処理の水準「0」を受ける群			
	1	1	...	1	0	0	...	0
被験者番号	1	2	...	10	11	12	...	20
$Y_{A=1}$	Y_{11}	Y_{21}	...	$Y_{10,1}$	$Y_{11,1}$ 欠測	$Y_{12,1}$ 欠測	...	$Y_{20,1}$ 欠測
$Y_{A=0}$	Y_{10} 欠測	Y_{20} 欠測	...	$Y_{10,0}$ 欠測	$Y_{11,0}$	$Y_{12,0}$...	$Y_{20,0}$

えることができる (表 1)。このことから、ルービン因果モデルではマッチング、層別解析、および、代入法などの欠測データ解析に基づく因果推論を行う。

集団に対する因果効果で最もよく利用されるものは平均因果効果 (または平均処置効果) である。平均因果効果は「処理 $A = a$ を受けた場合に観測されるであろう結果変数 Y (つまり、 Y_a)」と「処理 $A = a'$ を受けた場合に観測されるであろう結果変数 Y (つまり、 $Y_{a'}$)」との平均的な差 $E[Y_a] - E[Y_{a'}]$ で定義される。なお、記号 E は期待値 (平均) をとる作用素を表す。ここで、 $E[Y_a]$ という量は、処理 $A = a$ を割り付けられた集団における平均値 $E[Y|A = a]$ と等しいとは限らないことに注意が必要である。つまり、適当な条件下でなければ、実際に観測されるデータから推定可能な $E[Y|A = a]$ を処理の水準による群ごとに推定して比較しても、本当に知りたい潜在結果変数の期待値 $E[Y_a]$ を比較していることにはならない。このことは、交絡が常に存在していると考えられる観察研究で特に注意が必要であり、適切な推定のためには、試験デザインの工夫や種々の調整解析が必要となる。なお、ランダム化比較試験の場合でも、平均因果効果を推定するためにはいくつかの条件の成立の吟味が必要である。

ルービン因果モデルと並んで一般に利用されるもう 1 つの因果推論フレームワークとして、構造的因果モデルがある。潜在結果変数に基づくルービン因果モデルとは異なり、構造的因果モデルでは変数間の関数関係を規定し、各変数がこの関数関係にしたがって自律的かつ定期的生成されると仮定する。例えば図 2 上は、3 つの変数 X, A, Y 間の関数関係を構造方程式とよばれる式とグラフで表している。なお、このグラフのようにすべての辺が矢線で自身に戻るパスのないグラフのことを非巡回的有向グラフ (DAG) という。ここで、 $\epsilon_X, \epsilon_A, \epsilon_Y$ は各変数に影響を与える攪乱項であり、DAG では表示していない。

構造的因果モデルでは、介入とよばれる外的操作を通して因果効果を定義する。ある変数 A に対して




図 2. 構造方程式と DAG (上: 介入前, 下: 介入後).

何らかの操作によって A の値を $A = a$ に固定することを介入といい、do オペレータを用いて $do(A = a)$ と表現する。なお、このことは、DAG では介入を行う変数に向かう矢線を取り除くことに対応する (図 2 下)。

構造的因果モデルに基づく因果推論では、「 A に $A = a$ という介入を行ったときの Y の確率分布」を因果効果と定義する。潜在結果変数の場合と同様に、介入後の分布は、 $A = a$ を条件付けたもとの Y の単なる条件付き分布とは無条件には一致しないことに注意しよう。一致しない場合、 A と Y は交絡するといひ、観測されたデータに基づいて条件付き分布を単純に求めたとしても、それは介入を行ったときの Y の確率分布を求めていることにはならない。なお、ルービン因果モデルでは、潜在結果変数の期待値の差を平均因果効果と定義していた。構造的因果モデルでは、処理 A の水準を a と a' に固定する介入を行った後の Y の期待値の差 $E[Y|do(A = a)] - E[Y|do(A = a')]$ によって平均因果効果は定義される。

以上の 2 つのフレームワークに共通する重要な点は、因果効果が異なる世界間の比較によって定義されていることである。たとえば、平均因果効果とは母集団全体が処理の水準 $A = a$ を割り付けられた世界と、母集団全体が $A = a'$ を割り付けられた世界との比較によって定義されていた (図 3)。この比較は現実とは異なる世界 (反実仮想世界) を含むため、因果効果を観測データから単純に推定することはできない。そのため、種々の仮定のもとで因果効果を推定する方法が開発されている。なお、構造的因果モデルに基づいてルービン因果モデルを表現することができるが、それぞれに必要な仮定の確認のしやすさが学問領域によって異なるため、現状では、両



図3. 因果効果の視覚化 ([7]の Figure を改変). 円が母集団を表しており、黒色と白色がそれぞれ処理 $A = a$ と $A = a'$ の状態を表している. 右図では赤い点線により母集団全体が2つの部分集団に分割されている.

方のフレームワークを状況に応じて使い分けたり併用したりしている。

関連する話題

近年では、因果関係を捉えるための古典的な統計手法が、上述の2つのフレームワークに基づく方法へと拡張されている。たとえば、媒介変数をモデリングして変数間のメカニズムを解明しようとする媒介分析では、結果変数だけでなく媒介変数に対しても潜在的な値を仮定したモデルが開発されている [6]。これに関連して、筆者らは結果変数が順序カテゴリ変数の場合に、既存手法よりも弱い仮定のもとで利用可能な方法を提案している [5]。

推定対象としてよく利用される平均因果効果や動的介入効果 (図3右) などは、母集団全体もしくは母集団の部分集団に対して確定的な処理の水準の割付により定義されている。一方で、このような母集団全体への確定的な割付が現実には即していない場合がある。たとえば、運動促進キャンペーンが健康に与える影響を評価する際に、母集団全体に毎日30分の運動を行ってもらい介入を考えることはあまり意味がない (全く運動をしていない人にとっては運動促進となるが、もともと毎日1時間運動している人にとっては運動抑制となってしまう)。このように、各個人での現実の処理の水準の値に応じて割り付ける水準を変化させる確率的介入に関する研究が近年活発に行われており [1]、より実情に即した因果効果の検討が進められている。これに関連して、筆者は、因果効果の識別に必要な正值性に関して、既存手法よりも弱い仮定のもとで確率的介入に基づく因果効果を推定可能な方法を提案している [8]。

構造的因果モデルでは、DAGで表現されるような変数間の関係が特定されていることを前提としており、DAGが誤っている場合には、結果にバイアスが生じてしまう。そこで、正しいDAGをデータから推定しようとする因果探索 [4] とよばれる分野もあり、現在、理論・応用の両面で研究が進められ

ている。

おわりに

近年は医学、疫学、行動・社会科学などの分野だけでなく、潜在結果や介入に基づく因果推論はあらゆる科学領域に広がっている。たとえば、構造的因果モデルが常微分方程式系や確率微分方程式系に組み込まれることで、動的システムに基づく自然科学・社会科学研究で因果推論が利用可能となりつつある [3]。また、最近では生成AIと組み合わせた因果推論手法の開発なども行われており、その研究領域はまだまだ拡大している。このような状況で、筆者も目の前の興味深い問題を1つ1つ解決することで、因果推論手法の研究開発に貢献していきたい。

参考文献

- [1] Diaz, I., van der Laan, M. (2012). Population intervention causal effects based on stochastic interventions. *Biometrics*, 68(2), 541-549.
- [2] Holland, P. W. (1986). Statistics and causal inference. *Journal of the American Statistical Association*, 81(396), 945-960.
- [3] Peters, J., Bauer, S., Pfister, N. (2022). Causal models for dynamical systems. In *Probabilistic and Causal Inference: The Works of Judea Pearl* (pp. 671-690).
- [4] 清水昌平. (2017). 統計的因果探索. 講談社.
- [5] Tsubota, Y., Yamamoto, M. (2023). An alternative model-based approach to causal mediation analysis with ordinal outcomes. *Data Science, Statistics & Visualisation (DSSV) 2023*, July 5-7, University of Antwerp, p. 128.
- [6] VanderWeele, T. (2015). *Explanation in causal inference: methods for mediation and interaction*. Oxford University Press.
- [7] Westreich, D. (2017). From patients to policy: population intervention effects in epidemiology. *Epidemiology (Cambridge, Mass.)*, 28(4), 525-528.
- [8] Yamamoto, M. (2022). Estimation of the causal effects of stochastic interventions based on sufficient dimension reduction. *The 11th Conference of the IASC-ARS*, February 21-24, Doshisha University, p. 12.