

Title	EBPM と統計的因果探索・数理モデルの利活用
Author(s)	高山, 正行; 小柴, 等; 前田, 高志; 三内, 顕義; 清水, 昌平; 星野, 利彦
Citation	年次学術大会講演要旨集, 36: 752-757
Issue Date	2021-10-30
Type	Conference Paper
Text version	publisher
URL	http://hdl.handle.net/10119/17883
Rights	本著作物は研究・イノベーション学会の許可のもとに掲載するものです。This material is posted here with permission of the Japan Society for Research Policy and Innovation Management.
Description	一般講演要旨

EBPM と統計的因果探索・数理モデルの利活用

○ 高山 正行 (NISTEP), 小柴 等 (NISTEP), 前田 高志 ニコラス (NISTEP, 理研 AIP, 東京大学),
三内 顕義 (NISTEP, 理研 AIP), 清水 昌平 (NISTEP, 理研 AIP, 滋賀大学), 星野 利彦 (NISTEP)

1 はじめに

我が国においては、2016 年度からの第 5 期科学技術基本計画に前後してエビデンスに基づく政策立案（以下、EBPM: Evidence-Based Policy Making）に関する取組が進められ、2021 年度からの第 6 期科学技術・イノベーション基本計画においても、科学技術・イノベーション（以下、STI: Science, Technology and Innovation）行政において EBPM を徹底することとされ、内閣府などにおいても基礎データ整備の取組等が進められてきた。

EBPM の実践には複数のアプローチがあるが、各種政策変数間の因果関係の解明と定量的な効果予測も重要な要素の一つである。中でも因果推論についてはこれまで様々な手法が議論されてきたが、同時に様々な困難もあり、特に統計的因果探索を STI 政策立案に活用した例は未だない。それらも踏まえ文部科学省 科学技術・学術政策研究所 (NISTEP) では新たに、STI 政策研究に統計的因果探索のアルゴリズム “LiNGAM” [Shimizu06] の試行的応用を行っている。本報では STI 政策研究における因果推論のレビューと、統計的因果探索、特に LiNGAM の特徴、そしてこれを用いた今後の政策研究の応用の展望について述べる。また、数理モデルの構築に基づく定量的効果予測に向けた展望についても議論する。

2 政策研究の周辺領域の研究の進め方と EBPM におけるこれまでの取組

■ **研究のアプローチと類型** 一般に研究のスタイルは様々なものがあり、例えば吉川による分類 [吉川 08] では “ひとつの領域知識を使って、その領域知識と矛盾しない新しい知識を実現する” 第 1 種基礎研究と、“異なる領域知識を統合あるいは必要な場合には新知識を創出し、それを使って社会的に認知可能な機能を持つ人工物（ものあるいはサービス）を実現する研究” 第 2 種基礎研究に分類される。これらのアプローチの選択は目的や状況に応じて変わり、EBPM の推進にも各タイプの研究・

知識がバランス良く必要となる。例えば第 1 種基礎研究的に過去のデータに関して特定の観点からの原理追究、また、それに先立ってデータ収集・蓄積も重要だが、政策立案では第 2 種基礎研究的な様々な領域知識・知見の融合も重要である。第 1 種基礎研究がなければ第 2 種基礎研究は成立せず、第 1 種基礎研究だけでは知識をサービスに活かさない。




図 1: 第 1 種、第 2 種基礎研究のイメージ

■ **EBPM と研究の類型** EBPM という言葉が興る前から、政策科学分野においても前述の第 1 種基礎研究に相当する原理追究・データ分析に関する様々な取組がなされており、ある程度知見がたまっている。例えば STI 分野においては、国内では経済産業研究所 (RIETI)*1 や NISTEP で、論文や特許、博士人材など STI に関する様々な分析の報告書を見ることができる。また、2011 年度から 経済・社会等の状況を多面的な視点から把握・分析し、課題対応に向けた有効な政策の立案を行うために、「エビデンス・ベースド・ポリシー」の実現を目指して、文部科学省の補助事業として “科学技術イノベーション政策における「政策のための科学」推進事業” (SciREX 事業)*2 も進められている。他方、第 1 種基礎研究で得られた知見を基にした政策立案の支援など、政策分野における第 2 種基礎研究は相対的にその数が少ないように見受けられる。考えられる原因としては、第 1 種基礎研究の “特定の領域知識から知識を深掘り、分析を進める” アプローチは方針が明確に進めやすいのに対し、政策立

*1 <https://www.rieti.go.jp/>

*2 <https://scirex.grips.ac.jp/>

案では刻一刻と変化する社会環境の中で様々な要因を考慮しながら意思決定を行わなければならない、さらに、行政官が行うそれらの作業を研究者が観察することが難しい、といったことが挙げられる。また政策の多くは現在存在する、もしくは今後予見される課題に対して作られ、過去に関する詳細な分析の結果がそのまま未来に適用できるのか、あるいはその分析結果を基にある施策を計画したとして課題の解決に対してどの程度寄与するのか、定量的に見通すことが難しいことなども挙げられる。

■分析とシミュレーション 近年、いわゆる“人工知能”が様々な問題解決に用いられるが、その主な手法のひとつである統計的機械学習も上記と同様の問題を抱えている。例えば既存商品の売上の予測など、過去データとの関連が深い課題は上手く解決できるが、既存商品の市場を刷新する新商品が投入された場合の予測、また今後ヒットしそうな新たな商品のデザインは困難である*3。

こうした「ある環境に対し何らかの介入・操作を行った場合、状態や環境がどう変わるか」という問いに対応する手法は基本的にシミュレーションである。例えば、ある重さの弾を特定の角度と速度で打ち上げたら n 秒後に弾はどこに位置するか。さらに重さや角度、速度を変えた場合にならぬかについても予測することは比較的容易である。自然科学の多くの分野ではこうしたシミュレーションによるアプローチは様々な用いられている。これに比べ EBPM の文脈では、シミュレーションに基づく取組はこれまで多くは見られていなかった。これは前述の例では、物体の運動が従う物理法則（モデル）が明らかでかつシンプルのために予測・推定できたものの、EBPM の多くの場面ではモデルが明らかでないことに起因する。また、介入・操作に対して多数の異なる意思決定主体が相互に影響しながら環境を形成するという性質にも起因する。内閣官房新型コロナウイルス感染症対策推進室の“COVID-19 AI・シミュレーションプロジェクト”*4 は EBPM の文脈でも注目を集めているが、これも飛沫の拡散や感染伝搬のように、比較的広く認められている数理モデルによる感染症の拡大予測が主であり、政策的な介入・操作の定量的予測まで行っているものは少ない。

■計算社会科学 社会科学でも、例えば経済学では現象の的確な理解・記述のために様々な数理モデルが提案さ

れており、その確からしさの検証などにシミュレーションも活用されている。しかし、社会現象の多くは物理現象と違い基本的に構成概念であるので、同一の対象に複数のモデルが存在しうる難しさもあるし、過去においては、そもそもモデル構築に必要な事例・データが十分に集められないという問題もあった。後者の問題に関しては、ICT の発展・普及に伴い様々なデータの観測と分析が容易になったため、近年急速に取組が発展しつつあり、例えば計算社会科学という分野に成長している [鳥海 21]。ここでは、SNS でのヒット現象の数理モデルの解明などについて、Web 上のデータ収集や、マルチエージェントシミュレーション、ネットワーク分析などを活用した取組がなされている。

EBPM においても今後、計算社会科学と類似の文脈で、データからモデルを構築し、さらにそのモデルによりシミュレーションを行うことで、政策的介入を行った際の効果を予測し実践的な議論に繋げる、第 2 種基礎研究的な取組の加速が期待される。

■STI におけるシミュレーション 政策へのシミュレーション活用については、例えば日立製作所ではシミュレーションを用いた政策立案支援を行っている [嶺 19]。ここでは、専門家のワークショップでデータの因果関係を定性的に設定し、いくつかのパラメータを変化させて将来的なシナリオがどう変化するかを調査している。先に示した COVID-19 の例に加え、今後こうした取組はますます盛んになると期待される。

さて、STI に関する EBPM では先に述べた通り、これらの取組はあまり見られていない。これは前述の様々な課題に加え、以下をはじめ様々な要因でデータからの適切なモデル構築自体が一筋縄ではいかないことによる。例えば博士人材について調査しようと考えた場合、パネル調査は典型的に年 1 回程度しか実施できないため、データ点数は 10 年でも 10 点程度しか稼げない。また、個票データは二次利用申請が必要になるため利活用のハードルが高く、統計情報が主となるという制約もある。

3 モデル構築のこれまで

一般にモデル構築とは要素間の関係性を見つけ出し、そして/もしくは定義することといえる。大雑把にモデル構築のエッセンスを分解すると、

- 変数として取り入れるべき要素と因果関係の理解
- 関連する変数に基づいた数理的な構造の究明

*3 尤もらしい候補を全て作成させ、その中から人が良さそうなものを選んで試験する、というアプローチにならざるを得ない。

*4 <https://www.covid19-ai.jp/ja-jp/>

に分けられる。後者については別途5章にて後述すると
して、ここでは前者について STI 政策における現状を簡
単にレビューする。

理工学系・経済学系の領域では数式を用いたモデル構
築が一般的で、EBPM や STI 政策の文脈でもこれまで
様々な数理モデルが構築されてきた。特にデータからの
モデル構築について代表的な手法と具体例をいくつか
挙げると、例えば、回帰分析を使って分野融合と研究の
インパクトの関係を評価したもの [Okamura19]、共分散
構造分析により共同研究・受託研究活動の分析をしたも
の [中山 10]、操作変数法により科学技術の状況に関す
る質問項目間の関係性について定量分析を試みたもの
[福澤 15]、差分の差分法で環境規制と経済的効果につい
て定量分析を試みたもの [枝村 16]、などが挙げられる。
これらの手法の多くは、単なる相関関係を越えて、因果
関係を議論している点が重要である。

こうしたモデルが作れるとシミュレーションにより政
策立案の支援に繋がれる。しかし、これらの手法にも
限界はある。例えば、共分散構造分析ではあらかじめ変
数間の因果関係（因果パス）を定めるような手続きが必
要だったり、その他の手法も多くの変数が扱えない、特
定の変数に関する比較的単純な因果関係しか扱えない、
適用に当たって強い仮定をおく必要がある、などの制約
が存在する。あらかじめ、何らかのモデル、そしてその
前提としての変数間の因果関係が想定されている場合な
どでは、これらの手法は強力かつ有効だが、具体的関係
性が見えていない状況で、関係性自体を探索したいよ
うな場合には使いづらい。従って EBPM で求められる「多
数のパラメータ間の関係性を適切に読み取り、モデルに
落とし込む」という目的には適していなかった。

4 統計的因果推論

先述の因果推論について、改めて俯瞰的に因果探索と
の関係性も含めて整理する。その上で LiNGAM の概要
と具体の適用例について紹介する。

■因果推論と因果探索 因果推論、特に統計的因果推論
とはデータから因果効果を統計的に推定する手法であ
る。この際、目的変数とそれに関連する要素を集め、背
景知識等を元に因果関係を設定し、データからその妥当
性を定量的に検証する形で因果効果を推定することが
多い。代表的な手法は既に述べたとおり、回帰分析や操
作変数法、差分の差分法、共分散構造分析などが挙げら
れる。

因果推論の中でも、因果関係自体をデータから自動的
に見つけ出す（推測する）ような取組が因果探索に相当
する。何らかの背景知識を前提とする他の手法と比較
して、背景知識の必要性が低く、より多くの要素間の
複雑な関係性も考慮できるメリットがある。因果探索の
代表的な手法としては（因果）ベイジアンネットワーク
（以下、BN）、LiNGAM が挙げられる。これらの内容に
ついて図2にまとめた。




図2: 因果推論と因果探索の関係

■統計的因果探索の性質 既に述べたとおり、統計的因
果探索は利便性が高く期待と注目を集める手法であり、
様々なバリエーションが存在するが、ここでは一旦プリ
ミティブな BN、LiNGAM に議論を絞って説明する。

BN[Pearl 85] はベイズの定理に基づいた比較的古典的
な手法であり、これを用いた EBPM の取組の一例とし
ては地域健康政策の支援における活用 [鳥海 18] が挙げ
られる。しかし BN は2値変数の場合やカテゴリーによ
る分岐を考える際には強力であるが、連続変数が扱い難
い。そのため、アンケートなどで取得したカテゴリー変
数などには上手く使えても、予算や人数など間隔尺度以
上のデータには適用しづらいという課題もあった。

一方で近年、独立成分分析に基づいたアプローチ
を出発点として LiNGAM(Linear Non-Gaussian Acyclic
Model)[Shimizu06] という手法が開発され、連続値デー
タについての因果探索が可能になってきた。

表1: BN と LiNGAM

手法	変数の種別	アプローチ
BN	主に離散	ベイズ
LiNGAM	主に連続	独立成分分析

※BN: Bayesian Network

BN と LiNGAM の違いについて表1に簡単にまとめ
たが、例えばアンケートは分類尺度や順序尺度でデータ
が収集されるので、BN で分析するのに適している。一
方で、STI 政策関連のデータは論文数や特許数、博士人

材の数、予算など間隔尺度以上を扱うことも多く、これらは LiNGAM が適すると考えられる。いずれの因果探索の手法を使うにあたって、各手法の仮定⁵を満たすかどうか妥当性の考察は必ず必要となるが、これにより適切なモデルが構築できるならば EBPM を推進する上でも大きな補助として期待できる。特に我々は、STI 政策研究の文脈における多数の連続値パラメータの因果探索という点に着目し、LiNGAM の適用を試みている。

■LiNGAM ここで、詳細は教科書 [清水 17] に譲りつつ LiNGAM の特徴についてエッセンスのみ簡単に整理しておく。LiNGAM は以下の構造方程式モデルに基づく。

$$x_i = \sum_{j \neq i} b_{ij}x_j + e_i \quad (1)$$

ここで、 x_i (ただし、 $i = 1, 2, \dots, n$) は因果モデルにて考慮する n 個の変数、 b_{ij} は x_i に対して x_j が与える直接的な影響を線形の範囲で表す係数行列 $B = [b_{ij}]_{n \times n}$ の成分、そして e_i は変数 x_i の誤差変数 (外生変数) としている。狭義の LiNGAM においては、各変数間の関係が全て線形であること (この仮定は既に式 (1) を立てる段階で加味されている)、各変数の誤差項についての分布の非ガウス性、異なる変数の誤差項同士の独立性 (つまり未観測共通要因が存在せず、 $\text{cov}(f(e_i), g(e_j)) = 0$ (ただし、 f, g は任意の有界な関数) が $i \neq j$ で成り立つこと)、そして因果グラフの非巡回性を仮定する。これらの仮定の下、 $x_1 \sim x_n$ までの各変数に関するデータセットから係数行列 B を計算し、因果グラフを一意に識別することが可能となる。

推定アルゴリズムとしては、まず独立成分分析によるアプローチ [Shimizu06] が提案された。その後、回帰分析と誤差項の独立性評価を繰り返し、誤差項同士の相関の大きさ最小化することで因果的順序・係数行列の評価を行う手法 “DirectLiNGAM” が提案された [Shimizu11]。さらに、

- 時系列データで時間差を伴う効果がある場合の分析手法 [Hyvarinen10]
- bootstrap 法による再標本化と DirectLiNGAM の実行を繰り返すことによる、因果関係の有無・係数値の統計的信頼性の評価 [Komatsu10, Thamvitayakul12]
- 未観測共通要因がある場合であっても因果グラフの全体像を推定する手法 [Maeda20]

⁵ 例えば、BN も LiNGAM も基本的には有向非巡回性 (各変数間の関係がある場合は全て向きを持ち、因果関係が巡回しない) が仮定される。

等にも発展するなど、LiNGAM はその仮定を緩めつつ適用可能範囲を拡大している。

5 今後の科学技術政策への示唆

LiNGAM は、チュートリアルと共に様々なバリエーションも含めたプログラムのパッケージが既に公開されており⁶、Python の典型的な計算実行環境を準備し、因果関係を調べたい変数を定めてデータセットを構築すれば、ごく簡単な操作で因果探索が可能である。本年次大会の別講演の予稿 [高山 21b] に記載の通り、我々はまず博士課程進学率と関連する政策変数について、統計データに基づき因果関係がどのように表れるかという試行的分析を行っているが、他の STI 政策研究においても応用が期待できる。また、従来全く予想されていなかった政策変数同士の因果関係や交絡因子の存在が判明する可能性もあり、新たな政策的議論が期待される。

ただし、LiNGAM の活用はこの手法の単純利用だけで革新的な知見が直ちに得られることを意味しない。一定以上の理解・適切なデータセット構築を前提とした応用と、計算結果に基づいた科学的に意味ある議論の展開が重要であり、また数理モデルの構築との両輪で進めていくことで、原理的な理解やより高い精度での予測に向けた議論が可能となる。以下、留意事項と展望を述べる。

5.1 留意事項～統計的因果探索の政策研究への適切な応用に向けて

LiNGAM など因果探索は強力かつ便利である一方、利用に際しては様々な留意事項も存在する。例えば、何も考えなくても LiNGAM に何かしらのデータを投入すれば因果関係を出力してくれる。しかしながら、LiNGAM は原理的にそもそも要素 (変数) が独立であるという仮定をおいているため、変数の性質を理解した上でのデータセットの構築と必要に応じた事前知識の投入が必要となる。また変数間の独立性が保証できない場合には未観測共通要因の存在可能性のケアが必要である。このように、データそのものに関する理解と LiNGAM を用いた議論の進め方の理解は必須である。同様に、一切の背景・領域知識なく様々なデータを投入しても何らかの因果関係を示してくれるが、LiNGAM はあくまで数理的に解を導くに過ぎない。実用においてはデータ自体の理解に加えて分析結果を読み解く領域知識も極めて重要で、出てきた因果グラフが既存の領域知識に照らして適切なものかどうか確認し、必要に応じて方向性を修正したり、

⁶ <https://github.com/cdt15/lingam>

事前知識 (prior knowledge) を投入して再計算をさせるといった操作は LiNGAM を用いる上でも必須である。

また、データ項目やデータ点数を変えていくことで、因果グラフや係数も変化する。LiNGAM 自体は表計算ソフトでのマクロ利用と同程度の感覚で手軽に試せるので、過度なデータ加工・事前知識の投入を試行することによって想定する仮説に適合するよう分析結果を導くことも難しくはなく、こうした操作は究極的には EBPM の真逆の PBEM(Policy-Based Evidence Making) にも繋がってしまう。こうしたことが起こらないよう、データを使う側と見る側、双方のリテラシー向上も重要である。

5.2 展望～統計的因果探索・数理モデル構築の両輪による科学的理解・予測の実現

■STI 政策研究における数理的構造の究明 LiNGAM においては線形の構造方程式モデルを仮定しているが、定量分析の基本は線形解析にあり、前述の STI 政策関連の因果推論の研究についても線形解析をベースにしている。一方で厳密には線形の範囲で表される現象は少なく、3 章でも「関連する変数に基づいた数理的な構造の究明」というエッセンスについて触れたように、その非線形性を説明できるような数理的な構造の究明までたどり着くのが理想といえる。社会科学全般におけるアプローチとしては例えば鳥海らの著書 [鳥海 21] を参照されたいが、ここでは STI 政策における試みとそこで見える課題について、高山らの研究 [高山 21a] を例に簡単に紹介する。

この研究では 2025 年度の大学本務教員の年齢分布を予測するために、博士人材に関する人材流動を公開されている統計データを基に分析している。

図 3 には、公開されている統計データの分析の例を示した。図中 (a) ではポストドクターの年齢分布に関する公開データが実線の通り、非対称なピーク構造を持つ Gumbel 極値分布関数^{*7}でよくフィットされることを示している。また図中 (b) は、大学本務教員の新規採用者数を示している。なお (b) について学校教員統計調査では当該項目について 5 歳刻みの年齢階層別のデータしか公開していない一方、シミュレーションの都合上 1 歳刻みのデータが必要となるため、累積分布関数を適当な関数でフィットして推定するというプロセスをとっており、その結果を実線で示している。ここにおいても




図 3: 高山らの報告書 [高山 21a] における分析の例。

Gumbel 極値分布関数が主要な項となっている。

これらの分析を基に、確率遷移モデルを用いてその妥当性と共に推計を行った結果、2019 年度の予測値が実際の学校教員統計調査の結果にほぼ一致するなど、ある程度の精度をもつと見込まれるモデルを構築している。その一方、特に以下の点は全く未解決である。

- Gumbel 極値分布関数で予測まで含めてよく一致するようだが、現象論的/原理的な説明は何か。
- 上述の問題が解決されたとして、幅やピーク位置等のパラメータは何によって決まるのか。
- 性質の異なる人口の年齢分布であっても、この研究ではいずれも Gumbel 極値分布関数を主としたフィッティングが上手くいっているが、そもそもこうした社会現象を原理から説明できるような統一的な数理モデルが存在するのか。

他の STI 政策研究においても同様の課題に直面することが予想され、こういった課題を乗り越えるプロセスが必要である。例えば鳥海らの著書 [鳥海 21] では、物理学において確立した有効モデルを社会科学に転用し、パラメータの対応・意味づけを含めて説明する例を掲載しているが、必ずしも元の領域における全てのパラメータと社会現象のパラメータが 1 対 1 対応するわけではない。また、このようなプロセスで新たにパラメータが発生する場合もあり、その意味を他のパラメータとの因果関係も含めて究明することが求められる。これは上述した課題の中でも特に 2 つ目の問題と繋がり、数理的構造の究明という観点でも因果推論が重要な役割を果たすこ

^{*7} 年齢 n に対し、ピーク高さに対応するパラメータ A とピーク幅に対応するパラメータ τ 、そしてピーク位置を示すパラメータ n_0 を用いて $f(n) = \frac{A}{\tau} e^{-\frac{n-n_0}{\tau}} e^{-e^{-\frac{n-n_0}{\tau}}}$ と表現される。

とが期待される。

■統計的因果探索と数理モデル構築の関係性 上述のように、実は変数の特定・因果関係の決定と数理的構造の究明には切っても切れない関係があり、一体的な推進が望ましい。

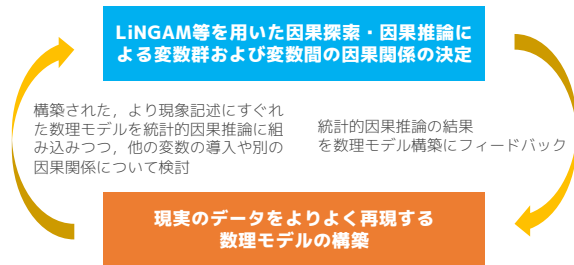


図 4: 因果探索・因果推論と数理モデル構築のサイクルによる量的研究のイメージ。

図 4 には、数理モデル構築によるアプローチと因果探索・因果推論のサイクルにより、EBPM を含めた社会科学における量的研究を行う上でのプロセスを示した。このアプローチにより、第 1 種基礎研究的な観点からは政策科学の数理的・原理的な現象解明の実現に繋がることが期待されるとともに、実践的な EBPM の観点からも、より説明性・納得性・予測性の高いモデルの構築を通じた最適な政策立案への貢献が期待される。

6 おわりに

本稿では、EBPM においても重要となる政策効果の予測モデルの構築・シミュレーションを念頭に、その鍵となる計算社会科学とモデル構築、そして因果推論について全体像をレビューし、特に統計的因果探索の手法の中でも LiNGAM の応用可能性について論じた。この統計的因果探索のアプローチと、社会科学現象を表現する数理モデルの構築を両輪で進めていくことにより、政策科学・EBPM のさらなる進展が期待される。

なお著者らは現在、博士課程進学率をテーマに LiNGAM を用いた分析及び上述の量的研究のサイクルの実践を試みており、それらの内容について本年次大会の別の講演 [高山 21b] にて発表予定である。

参考文献

[Hyvarinen10] A. Hyvärinen and K. Zhang and S. Shimizu and P. O. Hoyer: Estimation of a structural vector autoregression model using non-gaussianity.. *Journal of Machine Learning Research*, 11:1709–1731, 2010 <https://www.jmlr.org/papers/volume11/hyvarinen10a/hyvarinen10a.pdf>

[Komatsu10] Y. Komatsu, S. Shimizu, and H. Shimodaira: Assessing statistical reliability of LiNGAM via multiscale bootstrap.

In Proc. International Conference on Artificial Neural Networks (ICANN2010), Thessaloniki, Greece, pp.309–314, 2010. https://doi.org/10.1007/978-3-642-15825-4_40

[Maeda20] T. N. Maeda and S. Shimizu: RCD: Repetitive causal discovery of linear non-Gaussian acyclic models with latent confounders. *In JMLR Workshop and Conference Proceedings, AISTATS2020 (Proc. 23rd International Conference on Artificial Intelligence and Statistics), Palermo, Sicily, Italy.*, 735–745, 2020. <http://proceedings.mlr.press/v108/maeda20a/maeda20a.pdf>

[Okamura19] Keisuke OKAMURA: Interdisciplinarity revisited: evidence for research impact and dynamism. *Palgrave Commun.*, Vol.5, No.141, 2019. <https://doi.org/10.1057/s41599-019-0352-4>

[Pearl 85] Judea Pearl.: Bayesian Networks: a Model of Self-Activated Memory for Evidential Reasoning. *Proceedings, Cognitive Science Society*, 329–334, 1985. https://ftp.cs.ucla.edu/pub/stat_ser/r43-1985.pdf

[Shimizu06] S. Shimizu, P. O. Hoyer, A. Hyvärinen, and A. Kerminen: A linear non-gaussian acyclic model for causal discovery. *Journal of Machine Learning Research*, 7:2003-2030, 2006. <https://www.jmlr.org/papers/volume7/shimizu06a/shimizu06a.pdf>

[Shimizu11] S. Shimizu, T. Inazumi, Y. Sogawa, A. Hyvärinen, Y. Kawahara, T. Washio, P. O. Hoyer and K. Bollen.: DirectLiNGAM: A direct method for learning a linear non-Gaussian structural equation model. *Journal of Machine Learning Research*, 12(Apr): 1225–1248, 2011. <https://www.jmlr.org/papers/volume12/shimizu11a/shimizu11a.pdf>

[Thamvitayakul12] K. Thamvitayakul, S. Shimizu, T. Ueno, T. Washio and T. Tashiro.: Bootstrap confidence intervals in DirectLiNGAM. *In Proc., 2012 IEEE 12th International Conference on Data Mining Workshops (ICDMW2012), Brussels, Belgium*, pp.659–668, 2012. <https://doi.org/10.1109/ICDMW.2012.134>

[枝村 16] 枝村 一磨: 環境規制と経済的効果-製造事業所の VOC 排出に関する自主的取組に注目した定量分析. *NISTEP DISCUSSION PAPER*, No.133, 2016. <http://hdl.handle.net/11035/3132>

[清水 17] 清水 昌平: 統計的因果探索. 講談社 機械学習プロフェッショナルシリーズ, 2017.

[高山 21a] 高山正行, 星野利彦: 博士人材の年齢別人材流動モデルと試行的な将来予測. *NISTEP Discussion Paper*, No.193, Feb 2021. <https://doi.org/10.15108/dp193>

[高山 21b] 高山正行, 小柴等, 前田高志ニコラス, 三内顕義, 清水昌平, 星野利彦: 統計的因果探索アルゴリズム “LiNGAM” を用いた若手研究者支援政策に関する研究. *研究イノベーション学会 第 36 回年次学術大会 (予稿集)*, 公演番号 2G03, 2021.

[鳥海 18] 鳥海航, 生方裕一, 久野謙也, 岡田幸彦.: 地域健康政策へのベイジアンネットワークの応用. *統計数理*, Vol.66, No.2, pp.267–278, 2018. <https://www.ism.ac.jp/editsec/toukei/pdf/66-2-267.pdf>

[鳥海 21] 鳥海 不二夫 (編著): 計算社会科学入門. 丸善出版, 2021.

[中山 10] 中山 保夫, 細野 光章, 長谷川 光一, 永田 晃也: 産学連携データ・ベースを活用した国立大学の共同研究・受託研究活動の分析. *NISTEP Research Material*, No.183, 2010. <http://hdl.handle.net/11035/887>

[福澤 15] 福澤 尚美, 伊神 正貫: 科学技術の状況の俯瞰的可視化に向けて—NISTEP 定点調査 2011~2014 のパネルデータを用いた質問項目間の関係性についての定量分析—. *NISTEP DISCUSSION PAPER*, No.128, 2015. <http://hdl.handle.net/11035/3112>

[嶺 19] 嶺 竜治: 持続可能な未来の実現に資する「政策提言 AI」. *日立評論*, Vol.101, No.3, pp. 390–391, 2019.

[吉川 08] 吉川 弘之: 発刊に寄せて 第 2 種基礎研究の原著論文誌. *Synthesiology*, Vol.1, No.1, pp. 1–6, 2008.