

## 2.7.3 因果推論

### (1) 研究開発領域の定義

因果推論とは、物事や事象が起こる因果を調べるための数学的・統計学的方法論である。さらに、問題とする課題に対して、数理科学的に述べられた因果関係の推定・理解により課題解決を目指して意思決定を支援する手法を提示するための研究領域である。数学的方法論としては、a) 因果性に関するさまざまな概念を記述するための数理的枠組みづくり、b) その枠組みにおいて定式化された因果的特性がどのような仮定の下でデータから推定可能か、c) 推定可能であるなら、どうすれば精度よく推定できるか、そして、d) 仮定の妥当性をどう検討するか等に関する研究開発が含まれる。さらに、それらの方法論により領域知識とデータを組み合わせることで因果関係等を調べることにより、科学や社会（経済、金融、保険など）における課題解決のための意思決定支援を行うことが含まれる。

### (2) キーワード

統計学、機械学習、人工知能、確率解析、グラフ理論、反事実モデル、潜在反応モデル、構造的因果モデル、介入効果、反実仮想、交絡、無作為化（RCT）、標本選択バイアス、因果的機械学習、計量経済、金融工学、保険数理

### (3) 研究開発領域の概要

#### [本領域の意義]

因果関係（原因と結果の関係）の解明は科学の主目的の一つである。注意すべきは因果関係を知ることは相関関係を見ることとは異なる点である。さらに、それら因果関係に基づいて介入の効果等を評価することは、社会における課題解決のための意思決定に必要であることが多い。そのため、データから因果関係を推測するための数学的方法論を研究開発し体系化し、実際の問題解決のために効果的に用いることが、学術的にも社会的にも求められている。例えば、経済学や金融もしくは保険分野では、政策、社会制度、経営方針の変更等が何にどのような変化をもたらすかを数理の観点から予測することは、十分な情報に基づいた意思決定を行う上で必要不可欠である<sup>1)</sup>。実際ノーベル経済学賞の対象となるほど因果推論手法は経済学において根付いている。また、保険分野でも因果推論や機械学習などデータサイエンスと切り離すことができない。金融分野においては例えば時系列データ分析を用いて市場変動やデフォルト率変動などの要因を探ることは重要視されている。さらに、医学分野での病気・疾病と原因を探る営みはまさに因果効果を探ることにほかならないが、ここに言う因果推論はこうした分野での期待や需要も大きい。

一方、深層学習を含む機械学習が成熟したことにより、それに関する理論研究だけでなく、科学や工学のさまざまな分野において機械学習を課題解決に利用する研究が盛んに行われている。そこで研究開発された技術の実用化は、Webサービスを展開する企業や新薬や新材料探索を効率化したい企業を含め多くの企業や大学・研究機関で進んでいる。そして、文部科学省が大学レベルで「数理・データサイエンス・AI教育プログラム認定制度」をスタートさせるなど、機械学習は全国的な教育カリキュラムにも取り入れられ始めている。

全国的な教育に組み込まれるほど機械学習はなくてはならない手法となってきたが、それに伴い、現在の機械学習が「できること」と「できないこと」の区別も多くの人に認識されるようになった。また、機械学習技術がコモディティ化したことにより、自社サービスに独自性を示したい企業等が、機械学習が「できないこと」を実現する他の技術に興味を示している。従来の機械学習ができないことの代表例が、因果関係を推測することである。そのための方法論が、統計的因果推論である。

そのような背景があり、現在は、因果推論ブームにあると言われ、関連の書籍やセミナーが国内外で多数出版および開催されている。それに伴い、実際の適用事例も、従来の医学や経済学、金融等だけでなく、Webサービス関連、マーケティング、政治学、政策科学、化学、材料科学、気候学、農学、製造業など多様な領

域で数多く見られる。

#### • 歴史的な流れ

Jerzy Neyman (1923)<sup>2)</sup> により、無作為化実験の文脈で潜在反応という因果関係を定式化するためのアイデアが提案された。また、Ronald Fisher (1925)<sup>3)</sup> は無作為化実験の重要性を広めることに貢献した。Donald B. Rubinは、潜在反応のアイデアを無作為化実験以外も含めて、潜在反応モデルとして一般化した<sup>4)</sup>。Rosenbaum and Rubin (1983)<sup>5)</sup> により提案された傾向スコアは、複数の交絡要因を一つの変数にまとめることで、要因の組み合わせによっては条件に該当する対象者が少なくなりすぎる問題等を和らげ、因果分析の普及に貢献した。さらに、時間的に処置が変化する場合への対処は、James M. RubinがG-推定法を提案した<sup>6)</sup>。一方、Judea Pearlは、Sewall Wrightが提案したパス解析<sup>7)</sup> を基に計量心理学で発展した構造方程式モデリングや数学分野のグラフ理論を結びつけ、仮定を視覚的に表現する因果グラフを特徴とする構造的因果モデルを提案した<sup>8)</sup>。そして、交絡要因を選択する際によりどころとしてdo計算法を考案した<sup>8)</sup>。また、Peter Spirtesらにより、因果グラフをデータから推測する因果探索も分野として成立した<sup>9)</sup>。それらと並行して、操作変数法<sup>10)</sup> や差分の差分法<sup>11)</sup>、回帰不連続デザイン<sup>12)</sup>、標本選択バイアスへの対処法<sup>13)</sup> などが経済学分野から提案され、潜在反応モデルや構造的因果モデルの枠組みで裏付けされ精緻化された<sup>14)</sup>・<sup>8)</sup>。歴史については、8)、15)、16)、17)、18) がより詳しい。

### [研究開発の動向]

#### ① 数学的方法論に関する動向

##### • 因果性に関するさまざまな概念を記述するための数理的枠組みづくり

##### (反事実モデルで因果を定義)

現在の因果推論では、反事実モデルと呼ばれる考え方に基いて因果を定義する。例えば、「私」が薬を飲んで病気が治ったことを観測しただけでは、薬が原因で病気が治ったと言うには不十分であり、時間を巻き戻して「私」がもし薬を飲まなかった場合に病気が治らなかったことを観測すれば、薬が原因で病気が治ったと考えることができる。この2人の「私」は、同じ「私」のため、薬を飲んだか飲まなかったかのみに異なるから、病気の経過に違いが出れば、それは唯一の違いである薬を飲んだか飲まなかったかのせいだと考えるのである。ただし、実際には「私」は一人しかいないため、薬を飲んだ場合と飲まなかった場合の両方について病気が治ったか否かを観測することはできず、必ず一方は観測できない。観測できた方を事実、そうでない方を反事実と呼ぶ。それら二つの場合を比較することにより因果を定義するため、この考え方を反事実モデルと呼ぶ。

この定義からわかるように、個人レベルの因果効果をデータから知ることは原理的に不可能である。そのため、集団レベルの因果効果を調べるのが基本となる。上述の薬の例であれば、薬を飲んだか否か以外、集団としての性質が同じ二つの集団を比較し、病気が治った割合に違いがあるかを調べる。この集団レベルの因果効果を、端に因果効果あるいは介入効果と呼ぶ。

なお、反事実モデル以外にも、因果を定義する試みとしてグレンジャー因果や移動エントロピー、Convergent cross mapping<sup>19), 20)</sup> 等があるが、少なくとも現状では、定義としての採用は推奨されていないと思われる。これらは変数間の統計的関連性に基いて定義されているが、それら定義を満たす関係を見つけたとしても、必ずしも因果関係にはないからである。例えば、グレンジャー因果の場合であれば、分析に含まれていない変数が共通原因(交絡要因)となる場合が考慮されていない<sup>8)</sup>。ただし、これら方法を用了際、結果的に、反事実モデルに基いて定義される因果関係を推定できる場合はある。

##### (潜在反応モデル)

反事実モデルと言う考え方を数学的に表現するための代表的なフレームワークに潜在反応モデルがあ

る<sup>4), 14)</sup>。このフレームワークでは、観測されるかどうかにかかわらず薬を飲んだ場合の「私」と飲まなかった場合の「私」について病気が治るか否かをそれぞれ別々の変数で表し、潜在反応と呼ぶ。個人でなく集団を対象に薬を飲んだ場合と飲まなかった場合を比較する場合は、個人の添え字を落として病気が治ったかを確率変数として扱う。この記述の仕方を用いて、因果に関する概念や因果に関して調べたいことを表現する。例えば、介入効果や原因の確率等である。介入効果とは例えば、被検薬と偽薬を服用してもらうことで被検薬がどのくらい効果があるかであり、反事実の確率とは例えば、ワクチンを接種せずに新型コロナに感染しなかった人が、もしもワクチンを接種していたとしたら感染したであろうと考えられる確率である。潜在反応モデルの提案者は統計学者の Donald B. Rubin であり、特に統計学分野で広く研究され、経済学や医学を始め広く用いられている。

### (構造的因果モデル)

もう一つの代表的なフレームワークに、構造的因果モデルがある<sup>8)</sup>。このフレームワークでは、潜在反応モデルとは違い、薬を飲んだ場合の「私」と飲まなかった場合の「私」の病気が治ったかを別々の変数で表すことから始めるのではなく、まずデータの生成過程を構造方程式と呼ばれる数式を用いて表し、変数に介入することは、その変数の値を生成する構造方程式を変更することであると考えられる。そして、構造方程式を用いて潜在反応を求める。例えば、薬を飲ませるという介入を行う場合は、薬を飲んだか否かを表す変数を生成する方程式を、常に薬を飲むように変更する。その変更した新しいデータ生成過程において病気が治るかどうかを表す変数の値が、薬を飲むという処置を受けた場合の潜在反応となる。構造的因果モデルの提案者は計算機科学者の Judea Pearl であり、特に計算機科学や人工知能の分野で広く研究されている。条件付き独立性とグラフ理論を結びつけるグラフィカルモデルのアイデアや計量心理学で発展した構造方程式モデリング<sup>21)</sup>で蓄積されたアイデア（例えば、仮定を幾何学的に図示すること）も取り込まれている。なお、Peter Spirtesらによって、介入を因果グラフで表現するアイデアも同時期に発表されている<sup>9)</sup>。応用面では、歴史的に後発であるため、現状では潜在反応モデルの方が用いられている領域が多いと思われる。しかし、構造的因果モデルには、因果グラフと呼ばれる図示によって、仮定を視覚的に表現できるといった利点がある。この利点により、分析者が仮定の妥当性を検討したり領域知識を取り込んだりすることが、潜在反応モデルより容易になる。そのため、両方のフレームワークを適宜使い分ける分析者が増えている。なお、フレームワークの違いにより、データ分析の結論が異なることはないことが知られている<sup>8)</sup>。

### ・定式化された因果的特性がどのような仮定の下でデータから推定可能か

例えば、興味の対象となる代表的な因果的特性である介入効果をデータから推定するためには、集団としての性質が同質の集団をいかに用意するかが鍵となる。無作為化実験では、対象集団を無作為にグループ分けすること（無作為化/ランダム化）により、そのような集団をあらかじめ用意することができる。しかし、無作為化実験によらずに収集されたデータにより因果推論を行う際には、多くの工夫が必要となる。典型的な工夫としては、原因候補の変数の値を決定するような変数をすべて列挙し、それら変数に基づいて対象集団をグループ分けすることにより、同質の集団を用意する。例えば、重症かどうかのみによって薬を飲んだかどうかを決めているとしよう。重症かどうかによって病気が治るかどうかも変わるだろう。この場合は、重症度によってグループ分けすることによって、重症度について等質であって薬を飲んだかどうかのみが異なる集団を用意する。それができないと、病気にかかる割合に違いが出たとしても、薬を飲んだかどうかで違いが出たのか、重症かどうかで違いが出たのか区別できなくなる。これを交絡の問題と呼び、重症度のような因果関係を調べたい変数ペアに共通する原因を交絡要因と呼ぶ。交絡の問題を避けるために、どの変数についてグループ分けすべきかを判断することが、介入効果を推定する上で鍵となる。交絡の問題以外にも、特定の変数の値に依存して対象者を選んでしまうことにより対象集団には本来存在しない変数間の関連性が現れてしまうという標本選択バイアスの問題がある。



そのため、どのような条件で介入効果等の因果的特性を偏りなく推定できるかを数学的に明らかにすることが、因果推論において最も重要な研究項目の一つとなり、多くの研究が行われている。なお、データからそのような推定が可能であることを、識別可能であると言う。この識別性そのものに焦点を当てた研究が因果推論の大きな特徴である。潜在反応モデルの枠組みでは、強く無視できる割り当て条件がこれに対応する。また、構造的因果モデルの枠組みでは、Judea Pearlらによる因果グラフに基づくdo計算法がこれに対応し、その特殊形であるバックドア基準が特に有名である<sup>8)</sup>。また、時間的に処置が変化する場合については、計量生物学者のJames M. RubinのG-推定法等の成果が知られている<sup>6)</sup>。標本選択バイアスの問題への対処については、経済学者James Heckmanの成果が知られている<sup>13)</sup>。

#### ・推定可能であるなら、どうすれば精度（推定値が真値に近い）よく推定できるか

興味のある因果的特性がデータから推定可能であれば、つまり識別可能であれば、次は、どのように精度よく推定するかが焦点となる。例えば、グループ分けに用いる変数が多数になると、グループの数が多くなりすぎて、各グループに該当する対象者の数が少なくなりすぎ、推定が不安定になる恐れがある。多数の変数を1つの変数にまとめる代表的な方法に傾向スコア<sup>5)</sup>があり、それをを用いたさまざまな提案がある。

#### ・仮定の妥当性をどう検討するか

推定したい因果的特性が推定可能な条件を満たすかどうかは、分析者が採用した領域知識と設定した仮定による。そのため、分析者が設定した仮定に対してその妥当性の検討を行う。例えば、交絡の問題への対処としては、交絡要因のすべてを漏れなく分析に含めることが肝要であるが、漏れてしまう可能性は拭えない。その際、漏れてしまったかもしれない未観測の交絡要因によって分析の結論が覆るかどうかについてが関心事となる。そのため、このような未観測交絡要因による偏りの程度を見積もる感度分析を行う<sup>22)</sup>。また、分析者が設定した因果グラフから導かれる変数間の条件付き独立性が実際にデータで現れるかを調べることで、因果グラフに誤設定があるかを検討できる<sup>8)</sup>。

## ② 因果推論による意思決定支援に関する研究動向

因果推論は、疫学や経済学を始め、幅広い領域で課題解決のための意思決定支援に利用されている<sup>1), 23), 24)</sup>。医学分野等では、治療法の効果の検証等に標準的に用いられている。また、ビジネス分野でもオンラインで行う無作為化実験(A/Bテスト)を含め盛んに利用されるようになってきている。例えば近年では、コロナワクチンの集団予防接種の有効性の評価<sup>25)</sup>を始め、Obama元米国大統領がウェブサイトの改善に利用しメール会員登録を増やすことに役立てたとする事例等も社会の注目を集めた。これらに関する和文の教科書として、26)、27)、28)等がある。

また、操作変数法や差分の差分法、回帰不連続デザインなど、人為的でなく自然に生じた環境の変化を利用する自然実験に基づく手法も、潜在反応モデルや構造的因果モデルの枠組みの中で精緻化が進み、適用例が増加している。例えば、11)では、「最低賃金を上げることは雇用を減らすか?」というリサーチクエスチョンに答えるために、最低賃金を引き上げた州とそうでない州が存在することを利用して、引き上げた州がもし引き上げなかった場合の雇用の時間的変化が引き上げなかった州の雇用の時間的変化と同じという仮定の下、引き上げた州の雇用の変化と引き上げた州がもし引き上げなかった場合の雇用の変化の比較を行い、因果効果を計算した。12)では、選挙において現職が有利かどうかを調べるために、前回選挙で当落線上に近かった議員は、現職かどうか以外に差がないと仮定し、当落線上では、現職だった場合、(そうでない場合より)どのくらい当選しやすくなるかという因果効果を計算した。金融分野においては、例えば29)は、欧州の上場銀行において資産の担保差し入れが銀行の信用リスクを変化させるかを、操作変数法を用いて調べた。30)は、主要層ストラテジー<sup>31)</sup>と呼ばれる方法を用いてデビットカードを持っていても使用しない人がいることを考慮しつつ、イタリアの家計においてデビットカードの使用が現金需要

を減少させるかを、傾向スコアを用いて調べた。32) では、Bitcoinなどの暗号通貨に関して差分の差分法による因果分析が行われている。また、33) は、米国の中央銀行の判断と経済の状況との因果関係を調べるために、政策金利などの政策に関する変数、GDPやダウジョーンズコモディティ指数などを経済状況に関する変数として用いて因果探索による分析を行った。

定性的な因果関係（因果グラフ等）が領域知識から既知の場合に、直接観測可能な変数について因果関係を推論するための方法論は、成熟期を迎えたと言えるだろう。1970年前後から因果推論の発展に貢献した世代が現役を退き名誉教授等になる時期を迎え、それら因果推論に関する成果がチューリング賞（2011）やノーベル経済学賞（2000、2019、2021）の対象にもなった。チューリング賞受賞理由はベイジアンネットワーク<sup>34)</sup>であり、保険数理へ広く応用されている<sup>35)</sup>。これらノーベル経済学を受賞した開発経済学や労働経済学における因果推論の手法は、その後も隣接する教育経済学や公共経済学、都市経済学、さらにはそれ以外の分野へと拡大し、実証研究において何を外生要因とするかを明確に意識するようになった。さらに、アカデミアや産業界、官公庁等を含め広い領域で、因果推論が問題解決のために用いられている。

#### (4) 注目動向

2010年頃から、ビッグデータやデータサイエンス、AIなどをスローガンに、統計学や機械学習に関する学術的成果が、科学や社会においてさらに広く使われるようになった。因果推論は、それより前から、医学や経済学などの分野で利用されていたし、それら領域科学における需要を念頭に置いた方法論に関する研究も計量生物学、計量経済学、計量心理学、統計学、計算機科学、哲学等の研究者を中心に盛んに行われていた。ただ、それらスローガンの登場により、因果推論と機械学習の動機や技術の交流や相互乗り入れ、そして適用される領域の拡大などの変化があったように推測される<sup>36), 37)</sup>。

実際まず、i) 機械学習関連の研究者や実務家がアカデミアや産業界で大きく増えたこと、ii) そして機械学習が社会で広く利用されることにより、伝統的な機械学習の手法では答えられないリサーチクエストが方法論者以外の科学者や実務家に認知されたこと、また iii) 機械学習の成熟により、同領域に閉じた重要な研究トピックの減少などを背景にして、多くの機械学習の研究者が因果推論の研究も行うようになったことが挙げられる。また、因果推論の研究者も機械学習の成果を積極的に取り入れるようになってきている。

産業界では、米国や欧州、中国ではMicrosoftやAmazon、Google、Alibaba、Huawei等の大企業が因果推論に関するサービスを提供したり、分析パッケージを公開したり、そのために同分野の研究者の採用を積極的に行い、研究グループを形成し論文発表などにも力を入れたりなどしている。これら人材を継続的に輩出する因果推論に関する研究拠点が米国や欧州にはそれぞれ複数ある（Carnegie Mellon University、University of California, Los Angeles、Harvard University、Max-Planck-Institut、ETH Zürichなど）。中国でも清華大学がDonald B. Rubinを2018年より教授として迎えるなど因果推論に関する人材育成に力を入れていることが伺える。また、深層学習などの機械学習技術に基づくサービスだけでなく因果推論に基づくサービスを売りにする企業も、スタートアップを含め国内外で散見されるようになった。

#### [新展開・技術トピックス]

##### ① 因果推論のアイデアによる機械学習の改善

深層学習等の機械学習技術に基づくAIが社会実装されるに伴い、その信頼性の確保が重要となっている。当初は因果推論のアイデアはさほど使われてはいなかったと思われるが、信頼性の中でも公平性や説明性は因果推論の枠組みで定義され議論されてきた性質であったため、それを利用したAIの公平性や説明性を評価し向上させるための研究が盛んに行われている<sup>36)</sup>。

また、機械学習による予測性能は格段に向上したが、大きな課題の一つとして、環境が変化すると予測

精度が低下する問題があり、共変量シフトや転移学習、ドメイン適応などの名で研究されている<sup>38)</sup>。環境が変わっても予測精度を維持させるためには、環境が変わっても不変な特徴を利用する必要がある。そのような不変な特徴として、定性的な因果関係を利用することが注目を集めている。環境が変わり、因果の大きさや分布が変わっても、原因と結果の関係は変わらないだろうというアイデアである<sup>36)</sup>。因果推論の文脈では、外的妥当性の問題として研究されているが、技術交流が進んでいる<sup>39)</sup>。

## ② 機械学習のアイデアによる因果推論の改善

因果推論の理論によって、興味のある因果的特性、例えば、介入効果がデータから推定可能であるとわかった後、それを実際に推定する際に、機械学習の技術を使い推定精度を向上させようという試みがある。機械学習技術は予測を目的にしているため、何らかの補正をする必要があるが、特に高次元データを扱う際には有効である可能性がある<sup>40)</sup>。

また、分析者が設定した仮定、例えば、因果グラフの妥当性を検討する目的で変数間の条件付き独立性を調べることがある。その際、変数がガウス分布以外に従う場合や非線形の場合を扱う上で、カーネル法による独立性評価など機械学習の技術が使われている<sup>41)</sup>。

## ③ 因果推論と機械学習の融合による高次の知能を持つAIの実現へ

深層学習の登場により人間のような知能を持つ自律的なシステムが実現するのではないかという期待が高まっている。しかし、人間のような知能を持つには、因果の推定（推測）をAIがなせることが必要であるとして<sup>42)</sup>、深層学習を含む機械学習と因果推論の融合を目指す流れがある<sup>43)</sup>。実際に介入する前に、もし介入したらどのくらいの効果があるかを予測したり、実際には起きていないことがもし起きたらどうなるかといった反実仮想によるシミュレーションを行えたりすることが、従来の機械学習に基づくAIをより高次のレベルへ引き上げるために必要だという考え方である（反実仮想機械学習）。これにより、例えば、環境や状況の変化に適応し、未知の新しい状況でも適切な予測を行えるAIが実現するのではと期待されている<sup>15)</sup>。例えば、動画などから因果関係や変数定義を学習し、それを別のタスクへ活かすこと等が挙げられている（因果表現学習）<sup>37)</sup>。反実仮想機械学習や因果表現学習などは総じて因果的機械学習と呼ばれている<sup>36)</sup>。

仮にそのようなAIが実現し、領域知識やデータを自動的に収集する術が備われれば、領域知識とデータに基づき、因果関係を踏まえた仮説構築や検証をAIが自動的に行うことができるだろう。実現のためにまず必要なのが、潜在反応モデルや構造的因果モデルなどの因果関係を記述するための数学的フレームワークであった。そうしたことから、それらフレームワークの中で、リサーチクエスチョン、仮定、データの三つが与えられたときに、リサーチクエスチョンに答えることが可能か、可能なら答えは何かを計算するための原理や推定アルゴリズムに関する数理科学的研究が盛んに行われてきている。このような自律的なAIシステムは、Society 5.0におけるスマートシティ構想やデジタルツイン構想の実現を含め、人間が科学や社会における問題解決を行う際に大きな助けとなるだろう。

### [注目すべき国内外のプロジェクト]

#### ① 因果推論に関する国際学会、国際雑誌、国際会議が設立

- ・ The Society for Causal Inference (SCI) が2021年に設立された (<https://sci-info.org>)。設立前から毎年開催されていたAtlantic Causal Inference Conferenceを母体としている。年1回American Causal Inference Conferenceと週1回程度公開でOnline Causal Inference Seminarを開催している。
- ・ 北京国際数学研究中心 (Beijing International Center for Mathematical Research) の中で、清華大学と北京大学が主催して、Pacific Causal Inference Conferenceを2020年から国内外の研究者を年1回開催している。上記のAtlanticと対比させてPacificと銘打っているのだろう。
- ・ 2013年より、Judea Pearl教授をEditorの一人として、因果推論の専門誌 Journal of Causal



Inference (De Gruyterより出版) が刊行開始された。

- ・2022年より、因果推論専門の国際会議として Conference on Causal Learning and Reasoning (CLear) が始まり、査読付きプロシーディングスを出版している。

## ② 因果推論の研究教育拠点形成のための資金助成

米国国立衛生研究所 (NIH) のBD2K (Big Data to Knowledge) 事業において、ビッグデータから生物医学に関する知識を得るための因果推論の方法に関する研究教育拠点を形成するために、University of PittsburgやCarnegie Mellon Universityを中心にCenter for causal Modeling and discovery of Biomedical Knowledge from Big Dataを設置された<sup>1</sup>。交絡要因を調整することによる介入効果の推定という伝統的な因果分析以外の方法論の成果も、科学や社会で活用される段階に来たことを印象づけるプロジェクトであった。ただ、深層学習をベースとするような国レベルでの因果推論研究やその社会実装への投資は、世界的にまだ始まっていないと思われる。

## (5) 科学技術的課題

因果推論における主なボトルネックは、無作為化実験が実施できないような場合に生じる。したがって、多くの方法論研究は無作為化実験以外から得られたデータ (観察データ) による因果推論を対象としている。しかし、分野全体の意識としては、それだけに特化するのではなく、複数の母集団における無作為化実験から得られたデータとそれ以外の方法により得られたデータを領域知識と組み合わせて、よりよい因果分析を実現しようとする方向に進んでいる<sup>44)</sup>。

### ① 枠組みの拡張と仮定の妥当性の検討方法

交絡と標本選択バイアスが因果推論の二大困難である<sup>1), 44)</sup>。因果構造を表す因果グラフが非巡回の場合の理論は大きく発展したが、さらに実際の適用範囲を広げるには、それ以外の場合についても同水準にまで数学的な理論 (例えば、力学系や圏論など) を拡張・精緻化したりする必要があるだろう。例えば、対象者間に干渉があり得る場合、因果関係に巡回構造が見られる場合、因果関係が異なる複数の集団が混在する場合、因果関係が時間的に変化する場合、非平衡状態にある場合、変数の定義が事前に明確でない場合等があるだろう。

### ② 自動化による分析者の負担の軽減

因果推論を行うためには、データだけでなく領域知識が必要である。そのため、どのような領域知識に基づいて分析の仮定を設定するのかを分析者が判断しなければならない。したがって、分析者の負担を軽減し判断に焦点を合わせやすくすることが、因果推論が必要な場面で多くの人に使われるようになるためには必要であると思われる。例えば、領域知識を論文データベースから自動抽出したり、人間参加型の因果分析プロセスを構築したり、因果推論が介入したときの変化の分析であることを踏まえて結果を可視化したり、因果グラフをデータから推測したりすることが挙げられるだろう。個々の技術は各分野で行われているが<sup>45), 46), 9), 47)</sup>、それを効果的に結びつけ、一つの因果分析システムとして、分析者が比較的手軽にアクセス可能な状態にすること肝要であろう。

1 2014年-2019年, 5年間12.8M USD.  
<https://app.dimensions.ai/details/grant/grant.3860236>

(6) その他の課題

国内の大学等の機関において、一部の医学研究科所属の生物統計学関係の専攻を除いて、因果推論人材を継続的に輩出する仕組みや環境は十分でないと思われる（例えば、因果推論に関する教員が定常的に在籍するなど）。

また、政府のAI戦略2019を踏まえて、文部科学省「数理・データサイエンス・AI教育強化拠点コンソーシアム」がまとめたモデルカリキュラムにおいて、リテラシーレベルでは「相関と因果（相関係数、擬似相関、交絡）」、応用基礎レベルでは「相関関係と因果関係」がキーワードとして挙げられており、文理を問わず、全国の大学・高専生が学ぶことが目指されている。リカレント教育やリスキリングのための教育プログラムの設置や拡充も必要だろう。実務で因果推論を使っているとされる実務家教員も理論的背景については十分な知識を持っていない場合もある。因果推論の研究者や実務家等の数は、例えば、機械学習分野と比して、世界的に少ない。大学等において、医学に限らず幅広い適用領域で因果推論を教えることができる教員および因果推論に関する研究能力を持つ人材の養成が急務である。

因果推論の手法がノーベル経済学賞を受賞したことを背景とし、日本でもEBPM（evidence based policy making）に注目が集まるようになったが、科学としての精緻さを増した経済学的な政策分析は、一方で複雑でわかりにくい分析や解釈の難しい結果が示されるようになり、研究者と政策担当者（あるいは一般の人々）をつなぐ人材が必要になっている。

(7) 国際比較

国・地域	フェイズ	現状	トレンド	各国の状況、評価の際に参考にした根拠など
日本	基礎研究	○	↗	大学等では、医学研究科・薬学研究科所属の生物統計学関係の専攻 <sup>48)</sup> 、経済学研究科の計量経済学関係 <sup>49)</sup> 、統計学や機械学習関係の専攻等にて、因果推論に関する方法論研究が行われている。また、理化学研究所などの関連部局でも行われている <sup>50)</sup> 。因果探索分野で因果グラフの識別性に関して嚆矢となる研究も生まれている <sup>44)</sup> 。近年、機械学習分野でも因果推論に関する研究が行われるようになった分、研究成果や研究者数は増加しているが、欧米に比べれば研究者数は非常に少なく、継続的に研究成果を発表し人材を育成・輩出するためには、層を厚くする必要がある。
	応用研究・開発	△	↗	医学や疫学、経済学等において普及している。また、サイバーエージェント <sup>51)</sup> やNTTグループ <sup>52)</sup> 、富士通 <sup>53)</sup> 等の企業でも、因果推論に関する研究も見られる。NEC <sup>54)</sup> 、ニュートラル <sup>55)</sup> 、SCREEN <sup>56)</sup> 、ソニー <sup>57)</sup> など因果推論を行うソフトウェアや分析サービスを販売する企業も現れている。
米国	基礎研究	◎	↗	潜在反応モデルや構造的因果モデル、因果探索等について嚆矢となる成果を挙げたHarvard University <sup>58)</sup> 、University of California, Los Angeles、Carnegie Mellon University <sup>59)</sup> を中心に、University of WashingtonやJohns Hopkins University、Columbia University等が研究拠点として機能しており、研究成果の発表件数も多く、研究者の層が厚い。また、Columbia UniversityやUniversity of Montreal（カナダ）等の深層学習を含む機械学習研究拠点との連携も進み、その分、研究成果および研究者数は増えている。NeuIPS <sup>60)</sup> 、ICML <sup>61)</sup> 、KDD <sup>62)</sup> 、UAI <sup>63)</sup> など機械学習分野の主要国際会議で因果推論関係ワークショップやチュートリアルが行われている。
	応用研究・開発	○	↗	医学や疫学、経済学、政治学においてはよく普及している。生命科学、疫学や経済学、神経科学等について特に方法論に関する研究拠点との連携もよくなされている。さらに、Microsoft <sup>64)</sup> やGoogle <sup>65)</sup> 、IBM <sup>66)</sup> などの企業においても因果推論の研究チームがあり、分析パッケージを公開したりなどしている。



欧州	基礎研究	◎	↗	米国同様、因果推論に関する研究拠点が複数ある。英国のUniversity College London <sup>67)</sup> 、ドイツのMax-Planck-Institut <sup>68)</sup> 、スイスのETH Zürich <sup>69)</sup> 、フィンランドのUniversity of Helsinki <sup>70)</sup> 、ギリシャのUniversity of Crete <sup>71)</sup> 、オランダのUniversity of Amsterdam <sup>72)</sup> 等が挙げられる。米国同様に層は厚く、機械学習研究者との連携もよくなされている。因果推論の方法は主に米国で発展してきていると言えるだろうが、Jerzy Neymanが潜在反応モデルを無作為化実験の文脈で初めて提案したことに加え <sup>2)</sup> 、Ronald Fisherは無作為化が因果推論の強力な道具であることを広めるなどした <sup>3)</sup> 。
	応用研究・開発	○	↗	米国同様、生命科学、経済学等、それから気候学 <sup>73)</sup> について方法論に関する研究拠点との連携もよくなされている。Amazonドイツにおいて、Max-Planck-Institutの研究者と連携した因果推論の研究グループ <sup>74)</sup> が形成されている。また、因果推論を特長としたスタートアップ企業等もギリシャ <sup>75)</sup> や英国 <sup>76)</sup> 等で見られる。
中国	基礎研究	△	↗	北京大学 <sup>77)</sup> や清華大学 <sup>78)</sup> 、広東工業大学 <sup>79)</sup> などに拠点が形成されつつある。深層学習など機械学習研究者との連携もよくなされているが、まだ層が厚いとは言えないだろう。嚆矢となるような仕事についても目立った活動はまだ見られない。清華大学がDonald B. Rubin教授を迎えるなど力を入れていることは伺える。
	応用研究・開発	△	↗	Alibaba <sup>80)</sup> やHuawei <sup>81)</sup> 等の企業において、因果推論に関する論文発表が行われている。
韓国	基礎研究	△	→	目立った活動は見られない。
	応用研究・開発	△	→	目立った活動は見られない。

(註1) フェーズ

基礎研究：大学・国研などでの基礎研究の範囲

応用研究・開発：技術開発（プロトタイプの開発含む）の範囲

(註2) 現状 ※日本の現状を基準にした評価ではなく、CRDSの調査・見解による評価

◎：特に顕著な活動・成果が見えている

○：顕著な活動・成果が見えている

△：顕著な活動・成果が見えていない

×：特筆すべき活動・成果が見えていない

(註3) トレンド ※ここ1～2年の研究開発水準の変化

↗：上昇傾向、→：現状維持、↘：下降傾向

## 参考文献

- 1) Paul Hünermund and Elias Bareinboim, “Causal Inference and Data Fusion in Econometrics,” Arxiv, <https://doi.org/10.48550/arXiv.1912.09104>, (2023年3月8日アクセス) .
- 2) Jerzy Splawa-Neyman, D. M. Dabrowska, and T. P. Speed, “On the Application of Probability Theory to Agricultural Experiments. Essay on Principles. Section 9,” *Statistical Science* 5, no. 4 (1990) : 465-472., <https://doi.org/10.1214/ss/1177012031>.
- 3) Ronald Aylmer Fisher, *Statistical Methods for Research Workers* (Oliver & Boyd, 1925).
- 4) Donald B. Rubin, “Estimating causal effects of treatments in randomized and nonrandomized studies,” *Journal of Educational Psychology* 66, no. 5 (1974) : 688-701., <https://doi.org/10.1037/h0037350>.
- 5) Paul R. Rosenbaum and Donald B. Rubin, “The central role of the propensity score in observational studies for causal effects,” *Biometrika* 70, no. 1 (1983) : 41-55., <https://doi.org/10.1093/biomet/70.1.41>.
- 6) James M. Robin, “A new approach to causal inference in mortality studies with a sustained exposure period—application to control of the healthy worker survivor effect,” *Mathematical Modelling* 7, no. 9-12 (1986) : 1393-1512., [https://doi.org/10.1016/0270-0255\(86\)90088-6](https://doi.org/10.1016/0270-0255(86)90088-6).

- 7) Sewall Wright, "The Method of Path Coefficients," *The Annals of Mathematical Statistics* 5, no. 3 (1934) : 161-215., <https://doi.org/10.1214/aoms/1177732676>.
- 8) Judea Pearl, *Causality*, 2nd ed. (Cambridge: Cambridge University Press, 2009).
- 9) Peter Spirtes, Clark Glymour, and Richard Scheines, *Causation, Prediction, and Search*, 2nd ed. (MIT Press, 2001)., <https://doi.org/10.7551/mitpress/1754.001.0001>.
- 10) Philip Green Wright, *The Tariff on Animal and Vegetable Oils* (Macmillan, 1928).
- 11) David E. Card and Alan B. Krueger, "Minimum Wages and Employment: A Case Study of the Fast-Food Industry in New Jersey and Pennsylvania," *American Economic Review* 84, no. 4 (1994) : 772-793, <https://doi.org/10.3386/w4509>.
- 12) D. L. Thistlewaite and D. T. Campbell, "Regression-discontinuity analysis: An alternative to the ex post facto experiment," *Journal of Educational Psychology* 51, no. 6 (1960) : 309-317., <https://doi.org/10.1037/h0044319>.
- 13) James J. Heckman, "Sample Selection Bias as a Specification Error," *Econometrica*, 47, no. 1 (1979) : 153-161., <https://doi.org/10.2307/1912352>.
- 14) Guido W. Imbens and Donald B. Rubin, *Causal Inference for Statistics, Social, and Biomedical Sciences* (Cambridge: Cambridge University Press, 2015).
- 15) Judea Pearl and Dana Mackenzie, *The Book of Why: The New Science of Cause and Effect* (New York: Basic Books, Inc., 2018).  
ジューディア・パール, ダナ・マッケンジー『因果推論の科学:「なぜ?」の問いにどう答えるか』松尾豊 監, 夏目大 訳 (東京: 文藝春秋, 2022).
- 16) James H. Stock and Francesco Trebbi, "Retrospectives: Who Invented Instrumental Variable Regression?" *Journal of Economic Perspectives* 17, no. 3 (2003) : 177-194., <https://doi.org/10.1257/089533003769204416>.
- 17) Guido W. Imbens and Jeffrey M. Wooldridge, "Recent Developments in the Econometrics of Program Evaluation," *Journal of Economic Literature* 47, no. 1 (2009) : 5-86., <https://doi.org/10.1257/jel.47.1.5>.
- 18) Donald B. Rubin, "Causal Inference Using Potential Outcomes: Design, Modeling, Decisions," *Journal of the American Statistical Association* 100, no. 469 (2005) : 322-331., <https://doi.org/10.1198/016214504000001880>.
- 19) C. W. J. Granger, "Investigating Causal Relations by Econometric Models and Cross-spectral Methods," *Econometrica* 37, no. 3 (1969) : 424-438., <https://doi.org/10.2307/1912791>.
- 20) George Sugihara, et al., "Detecting Causality in Complex Ecosystems," *Science* 338, no. 6106 (2012) : 496-500., <https://doi.org/10.1126/science.1227079>.
- 21) Kenneth A. Bollen, *Structural Equations with Latent Variables* (John Wiley & Sons, Inc., 1989).
- 22) Peng Ding and Tyler J. VanderWeele, "Sensitivity Analysis Without Assumptions," *Epidemiology* 27, no. 3 (2016) : 368-377., <https://doi.org/10.1097/EDE.0000000000000457>.
- 23) Miguel A. Hernán and James M. Robins, *Causal Inference: What If* (CRC Press, 2020).
- 24) Stephen L. Morgan and Christopher Winship, *Counterfactuals and Causal Inference: Methods and Principles for Social Research*, 2nd ed., Analytical Methods for Social Research (Cambridge: Cambridge University Press, 2014)., <https://doi.org/10.1017/CBO9781107587991>.
- 25) Noa Dagan, et al., "BNT162b2 mRNA Covid-19 Vaccine in a Nationwide Mass Vaccination Setting," *New England Journal of Medicine* 384 (2021) : 1412-1423., <https://doi.org/10.1056/>

- NEJMoa2101765.
- 26) 安井翔太『効果検証入門:正しい比較のための因果推論/計量経済学の基礎』株式会社ホクソエム 監 (東京: 技術評論社, 2020).
  - 27) 高橋将宜『統計的因果推論の理論と実装:潜在的結果変数と欠測データ』石田基広 監, 市川太祐, 他 編, Wonderful R 5 (東京: 共立出版, 2022).
  - 28) 星野崇宏『調査観察データの統計科学:因果推論・選択バイアス・データ融合』確率と情報の科学 (東京: 岩波書店, 2009).
  - 29) Emilia Garcia-Appendinia, Stefano Gattib, and Giacomo Nocera, “Does asset encumbrance affect bank risk? Evidence from covered bonds,” *Journal of Banking & Finance* 146 (2023) : 106705., <https://doi.org/10.1016/j.jbankfin.2022.106705>.
  - 30) Andrea Mercatanti and Fan Li, “Do Debit Cards Decrease Cash Demand?: Causal Inference and Sensitivity Analysis Using Principal Stratification,” *Journal of the Royal Statistical Society. Series C: Applied Statistics* 66, no. 4 (2017) : 759-776., <https://doi.org/10.1111/rssc.12193>.
  - 31) Constantine E. Frangakis and Donald B. Rubin, “Principal Stratification in Causal Inference,” *Biometrics* 58, no. 1 (2002) : 21-29., <https://doi.org/10.1111/j.0006-341X.2002.00021.x>.
  - 32) Shimeng Shi and Yukun Shi, “Bitcoin futures: trade it or ban it?” *The European Journal of Finance* 27, no. 4-5 (2021) : 381-396., <https://doi.org/10.1080/1351847X.2019.1647865>.
  - 33) Alessio Moneta, et al., “Causal Inference by Independent Component Analysis: Theory and Applications,” *Oxford Bulletin of Economics and Statistics* 75, no. 5 (2013) : 705-730., <https://doi.org/10.1111/j.1468-0084.2012.00710.x>.
  - 34) Judea Pearl, *Causality: Models, Reasoning and Inference* (Cambridge: Cambridge University Press, 2000).
  - 35) Barry Sheehan, et al., “Semi-autonomous vehicle motor insurance: A Bayesian Network risk transfer approach,” *Transportation Research Part C: Emerging Technologies* 82 (2017) : 124-137., <https://doi.org/10.1016/j.trc.2017.06.015>.
  - 36) Jean Kaddour, et al., “Causal Machine Learning: A Survey and Open Problems,” Arxiv, <https://doi.org/10.48550/arXiv.2206.15475>, (2023年3月8日アクセス) .
  - 37) Bernhard Schölkopf, et al., “Toward Causal Representation Learning,” *Proceedings of the IEEE* 109, no. 5 (2021) : 612-634., <https://doi.org/10.1109/JPROC.2021.3058954>.
  - 38) Joaquin Quinonero-Candela, et al., eds., *Dataset Shift in Machine Learning* (MIT Press, 2008)., <https://doi.org/10.7551/mitpress/9780262170055.001.0001>.
  - 39) Elias Bareinboim and Judea Pearl, “Causal inference and the data-fusion problem,” *PNAS* 113, no. 27 (2016) : 7345-7352., <https://doi.org/10.1073/pnas.1510507113>.
  - 40) Victor Chernozhukov, et al., “Double/debiased machine learning for treatment and structural parameters,” *The Econometrics Journal* 21, no. 1 (2018) : C1-C68., <https://doi.org/10.1111/ectj.12097>.
  - 41) Jonas Peters, Dominik Janzing, and Bernhard Schölkopf, *Elements of Causal Inference: Foundations and Learning Algorithms* (MIT Press, 2017).
  - 42) Judea Pearl, “Causal Inference: History, Perspectives, Adventures, and Unification (An Interview with Judea Pearl),” *Observational Studies* 8, no. 2 (2022) 1-14., <https://doi.org/10.1353/obs.2022.0007>.
  - 43) Payal Dhar, “Understanding Causality Is the Next Challenge for Machine Learning,” *IEEE Spectrum*, <https://spectrum.ieee.org/tech-talk/artificial-intelligence/machine-learning/>



understanding-causality-is-the-next-challenge-for-machine-learning, (2023年3月8日アクセス) .

- 44) Judea Pearl, “The seven tools of causal inference, with reflections on machine learning,” *Communications of the ACM* 62, no. 3 (2019) : 54-60., <https://doi.org/10.1145/3241036>.
- 45) 和泉潔, 坂地泰紀, 松島裕康『金融・経済分析のためのテキストマイニング』テキストアナリティクス 6 (東京: 岩波書店, 2021).
- 46) 鹿島久嗣, 小山聡, 馬場雪乃『ヒューマンコンピューテーションとクラウドソーシング』機械学習プロフェッショナルシリーズ (東京: 講談社, 2016).
- 47) Shohei Shimizu, *Statistical Causal Discovery: LiNGAM Approach*, SpringerBriefs in Statistics (Tokyo: Springer, 2022)., <https://doi.org/10.1007/978-4-431-55784-5>.
- 48) 京都大学大学院医学研究科 社会健康医学系専攻 医療統計学 [http://www.kbs.med.kyoto-u.ac.jp/member\\_sato.html](http://www.kbs.med.kyoto-u.ac.jp/member_sato.html), (2023年3月8日アクセス) .  
東京大学大学院 医学研究科 公共健康医学専攻 生物統計学分野 <http://www.epistat.m.u-tokyo.ac.jp/about/>, (2023年3月8日アクセス) .
- 49) 東京大学大学院経済学研究科経済専攻 経済学コース <https://www.e.u-tokyo.ac.jp/fservice/faculty/viewrfj.html>, (2023年3月8日アクセス) .
- 50) 理化学研究所革新知能統合研究センター, 因果推論チーム [https://www.riken.jp/research/labs/aip/generic\\_tech/cause\\_infer/](https://www.riken.jp/research/labs/aip/generic_tech/cause_infer/), (2023年3月8日アクセス) .  
理化学研究所革新知能統合研究センター, 経営経営情報融合分析チーム [https://www.riken.jp/research/labs/aip/ai\\_soc/bus\\_econ\\_inf\\_fusion\\_anl/index.html](https://www.riken.jp/research/labs/aip/ai_soc/bus_econ_inf_fusion_anl/index.html), (2023年3月8日アクセス) .
- 51) CyberAgent, Inc. AI Lab <https://cyberagent.ai/ailab/>, (2023年3月8日アクセス) .
- 52) NTTコミュニケーション科学基礎研究所, 知能創発環境研究グループ <http://www.kecl.ntt.co.jp/icl/labs/research.html>, (2023年3月8日アクセス) .
- 53) 理研 AIP- 富士通連携センター  
国立研究開発法人理化学研究所 革新知能統合研究センター (AIP)「多変数データを用いた非線形因果探索技術の開発」 [https://aip.riken.jp/news/20220426\\_pressrelease\\_aip-fujitsu/?lang=ja](https://aip.riken.jp/news/20220426_pressrelease_aip-fujitsu/?lang=ja), (2023年3月8日アクセス) .
- 54) 日本電気株式会社 (NEC) causal analysis : 因果分析ソリューション <https://jpn.nec.com/solution/causalanalysis/index.html>, (2023年3月8日アクセス) .
- 55) ニュートラル株式会社 因果探索・未来予測ソリューション『NTech Predict』, <https://www.ipros.jp/product/detail/2000690909/>, (2023年3月8日アクセス) .
- 56) 株式会社SCREEN アドバンスドシステムソリューションズ 因果探索ソリューション <https://www.screen.co.jp/as/solution/causal>, (2023年3月8日アクセス) .
- 57) 株式会社ソニーコンピュータサイエンス研究所 (ソニー CSL) CALC <https://www.sonycscl.co.jp/tokyo/7593/>, (2023年3月8日アクセス) .
- 58) Department of Statistics, Harvard University, <https://statistics.fas.harvard.edu>, (2023年3月8日アクセス) .  
Harvard T.H. Chan School of Public Health, CAUSALab, <https://causalab.sph.harvard.edu>, (2023年3月8日アクセス) .
- 59) CMU-CLeaR Group, Carnegie Mellon University, <https://www.cmu.edu/dietrich/causality/>, (2023年3月8日アクセス) .
- 60) NeurIPS2021 Causal Inference & Machine Learning: Why now?, <https://why21.causalai.net>, (2023年3月8日アクセス) .

- NeurIPS2020 Workshop: Causal Discovery & Causality-Inspired Machine Learning, <https://www.cmu.edu/dietrich/causality/neurips20ws/>, (2023年3月8日アクセス) .
- 61) Nan Rosemary Ke and Stefan Bauer, “Causality and Deep Learning: Synergies, Challenges and the Future,” ICML 2022 Tutorial, <https://sites.google.com/view/causalityanddeeplearning/start>, (2023年3月8日アクセス) .
- 62) The 2022 ACM SIGKDD Workshop on Causal Discovery, <http://4llab.net/workshops/CD2022/index.html>, (2023年3月8日アクセス) .  
The 2021 ACM SIGKDD Workshop on Causal Discovery, <https://nugget.unisa.edu.au/cd2021.html>, (2023年3月8日アクセス) .
- 63) Yoshua Bengio and Nan Rosemary Ke, “Tutorial: Causality and Deep Learning: Synergies, Challenges & Opportunities for Research,” 38th Conference on Uncertainty in Artificial Intelligence (UAI 2022), <https://www.auai.org/uai2022/tutorials>, (2023年3月8日アクセス) .
- 64) Causality and Machine Learning, Microsoft, <https://www.microsoft.com/en-us/research/group/causal-inference/>, (2023年3月8日アクセス) .  
Microsoft, DoWhy, <https://github.com/py-why/dowhy>, (2023年3月8日アクセス) .
- 65) CausalImpact, Google, Inc., <https://google.github.io/CausalImpact/CausalImpact.html>, (2023年3月8日アクセス) .
- 66) Causal Inference 360 Open Source Toolkit, IBM, <https://cif360-dev.mybluemix.net>, (2023年3月8日アクセス) .
- 67) Department of Statistical Science, University College London, <https://www.ucl.ac.uk/statistics/people/ricardosilva>, (2023年3月8日アクセス) .
- 68) Causal Inference, Max Planck Institute for Intelligent Systems, [https://ei.is.mpg.de/research\\_projects/causal-inference](https://ei.is.mpg.de/research_projects/causal-inference), (2023年3月8日アクセス) .
- 69) Seminar for Statistics, ETH Zürich, <https://math.ethz.ch/sfs>, (2023年3月8日アクセス) .
- 70) Department of Computer Science, University of Helsinki, <https://www.cs.helsinki.fi/u/ahyvarin/>, (2023年3月8日アクセス) .
- 71) Department of Computer Science, University of Crete, <http://mensxmachina.org/en/>, (2023年3月8日アクセス) .
- 72) Amsterdam Machine Learning Lab (AMLab), University of Amsterdam, <https://amlab.science.uva.nl>, (2023年3月8日アクセス) .
- 73) Causal Inference and Climate Informatics Group, German Aerospace Center’s Institute of Data Science, <https://climateinformaticslab.com>, (2023年3月8日アクセス) .
- 74) Amazon  
<https://www.amazon.science/blog/honorable-mention-to-amazon-researchers-for-icml-test-of-time-award>, (2023年3月8日アクセス) .  
<https://www.amazon.science/author/dominik-janzing>, (2023年3月8日アクセス) .
- 75) Gnosis Data Analysis, <https://www.gnosisda.gr>, (2023年3月8日アクセス) .
- 76) Actable AI Technologies LTD, <https://www.actable.ai>, (2023年3月8日アクセス) .  
causaLens, <https://www.causalens.com>, (2023年3月8日アクセス) .
- 77) Department of Biostatistics, Peking University, [https://sph.pku.edu.cn/English/Faculty/Department\\_of\\_Biostatistics.htm](https://sph.pku.edu.cn/English/Faculty/Department_of_Biostatistics.htm), (2023年3月8日アクセス) .
- 78) Yau Mathematical Sciences Center, Tsinghua University, <https://ymsc.tsinghua.edu.cn/en/info/1031/1879.htm>, (2023年3月8日アクセス) .

- 79) Data Mining and Information Retrieval Laboratory, Guangdong University of Technology, <https://dmir.gdut.edu.cn>, (2023年3月8日アクセス) .
- 80) Decision Intelligence Lab, DAMO Academy, Alibaba <https://damo.alibaba.com/labs/decision-intelligence>, (2023年3月8日アクセス) .
- 81) Huawei Technologies Noah's Ark Lab, <http://dev3.noahlab.com.hk>, (2023年3月8日アクセス) .

## 2.7

### 俯瞰区分と研究開発領域 数理科学