

# 金融分野における因果推論の展開

## — 統計的手法・因果 AI・自然言語処理の三潮流とその展望 —

和泉 潔 | 東京大学大学院工学系研究科 教授



和泉 潔

東京大学大学院工学系研究科教授。1993年東京大学教養学部基礎科学科第二卒業。1998年同大学院総合文化研究科広域科学専攻博士課程修了、博士(学術)。同年、電子技術総合研究所(現・産業技術総合研究所)に入所し、2010年まで勤務。2010年より東京大学大学院工学系研究科システム創成学専攻准教授、2015年より現職。専門は金融情報学、市場シミュレーション、金融データマイニング。IEEE、人工知能学会、情報処理学会、電子情報通信学会会員。

### 要約

本稿は、金融分野における因果推論の主要な三つの潮流を整理し、それぞれの背景・手法・応用事例を概観する。第一は統計的因果推論であり、政策効果測定や企業ガバナンスの影響分析といった実証研究に広く用いられている。第二は機械学習技術を活用した因果 AI であり、複雑・高次元データによる金融予測、非定常時系列における因果構造の発見、さらには説明可能な AI (XAI) への応用が進展している。第三は自然言語処理を用いた因果推論であり、稀な経済現象の要因解明、企業への経済変動の影響分析、株価に対するニュースインパクトやリード・ラグ効果の分析など、経験的因果の知識を活用する領域に应用されている。今後は、大規模言語モデル (LLM) と統計的因果推論の融合や、反実仮想シナリオを用いたエージェントシミュレーションの導入により、因果推論の精度が向上し、応用範囲が拡大することが期待される。

### 1. 経済・金融は因果で動く

経済ニュース記事や相場解説では、株価の動き、商品の売り上げ、雇用、貿易といった経済事象における因果関係が頻繁に登場する。たとえば、「将来の少子高齢化が〇〇を引き起こし、それに関連した〇〇への需要が増加する」、あるいは「現在の株価下落は〇〇による市場参加者のリスク警戒心理を反映している」といった形で、経済事象の波及効果やその原因が説明される。このように、因果関係は経済や金融の動きを理解し説明する際に中心的な役割を果たしている。さらに、人々はこうした因果関係の理解に基づいて経済行動を選択し、それらの行動の集積が新たな経済現象を生み出していく。経済は、因果関係の理解と行動の連鎖によって日々動いているのである。

この因果への注目性は、日常的な経済理解にとどまらない。アダム・スミスの『国富論』(Smith, 1776) の原題に「原因 (causes)」という語が含まれているように、因果関係は経済学の基本的概念である。この伝統はアリストテレスにまで遡り、経済学は長らく物理学をモデルとしながら、経済現象における因果法則の解明を目指してきた (Hoover, 2018)。哲学者であり経済学者でも

あったデイヴィッド・ヒュームは、実践的な経済学を本質的に因果科学として捉え、「原理を知ることが公共政策の実行において有用である」と主張している (Hume, 1785)。一方で彼は、因果関係の本質を完全に理解することには懐疑的であり、この因果関係の認識論的な限界と政策的応用との間の緊張関係は、ヒューム以降の経済分析においても一貫して問題となり続けている。

### 1.1 背後の因果関係を知らなければ大規模データは価値を持たない

近年の金融市場分析では、従来の経済統計や財務諸表に加え、ソーシャルメディア、衛星画像、購買履歴など、これまで活用されてこなかった多種多様な大規模データの利用が急速に進展している。これら「オルタナティブデータ」は高度な機械学習技術と組み合わせられ、金融機関は自社あるいは外部の情報技術者に最先端の機械学習手法を適用させ、より優位な分析手法の開発を推進している。しかし、データの背景にある構造的関係、特に因果関係を無視したまま、膨大な情報を機械的に処理して投資戦略に反映させるアプローチは、長期的に深刻なリスクを伴う可能性がある。

実際に、Dessaint et al. (2024) は、オルタナティブデータの利用が短期予測の精度を高める一方で、長期的な市場予測にはむしろ負の影響を及ぼすことを示している。Institutional Brokers' Estimate System (I/B/E/S) のデータを用いた分析によれば、1980年代以降、アナリストによる1日~1年先の業績予測精度は向上しているが、2年以上先の長期予測精度は一貫して低下している。特にソーシャルメディア (Stocktwits など) へのアクセス頻度の高いアナリストほど、短期予測の精度は0.54ポイント改善する一方で、長期予測は1.51ポイント低下しており、長期予測能力の相対的な劣化が観察される。

過去データへの過信が構造変化に対応できないというデータ駆動型アプローチの限界は、以下の事例に顕著である。1998年には、ロングターム・キャピタル・マネジメント (LTCM) がロシア危機という想定外の事態に対処できず破綻した。2013年のツイッター・クラッシュでは、ホワイトハウスで爆発という誤報にアルゴリズム取引が過剰反応し、市場に混乱をもたらした。さらに、2020年のCOVID-19感染拡大では、ビッグデータに基づく定量的ファンドが未曾有の事態に対応できず、大きな損失を被った。これらの事例は、金融市場における大規模データの活用が分析の精緻化と即時性をもたらす一方で、データの背後にある経済事象の波及効果や要因の理解という長期的かつ広範な視点を欠けば、投資判断の誤謬やシステミックリスクを引き起こす可能性があることを示している。今後の市場分析においては、単なる統計的相関に依拠するのではなく、人間行動や制度的背景を含む経済事象の構造的理解に基づいた因果関係の把握が不可欠である。

## 2. 因果推論：因果関係の解明に挑む科学的アプローチ

因果推論 (causal inference) とは、観察データから、単なる相関関係で

はなく、原因と結果の関係を推定する手法である。Pearl and MacKenzie (2018) は、因果関係を理解するためには、人間が観察、介入、反事実という三つのレベルの認知能力を備えている必要があると述べている (図表 1)。これらは、本稿で紹介する因果推論の全ての手法の基礎となっている。

図表 1.

<p>1. 関連付け (Association) : 見る能力 観察に基づく理解。「Xを見たらYが起きることが多い」など、データ間のパターンを読み取る。 例: 株価が下がると金価格が上がる人が多い。</p>
<p>2. 介入 (Intervention) : 行動する能力実際に行動・介入した場合に何が起こるかを予測し、介入を行う (行わない) を判断する能力。 例: 中央銀行が金利を下げたら、住宅市場にどのような影響が出るか?</p>
<p>3. 反事実 (Counterfactual) : 想像する能力 「もしあのとき別の選択をしていたら?」という仮想的な過去に立ち返る思考。物事の原因を深く理解しようとする能力。 例: もし破綻した金融機関 Z が救済されていたら、金融危機は防げたのか?</p>

出所) Pearl and MacKenzie (2018) より筆者作成

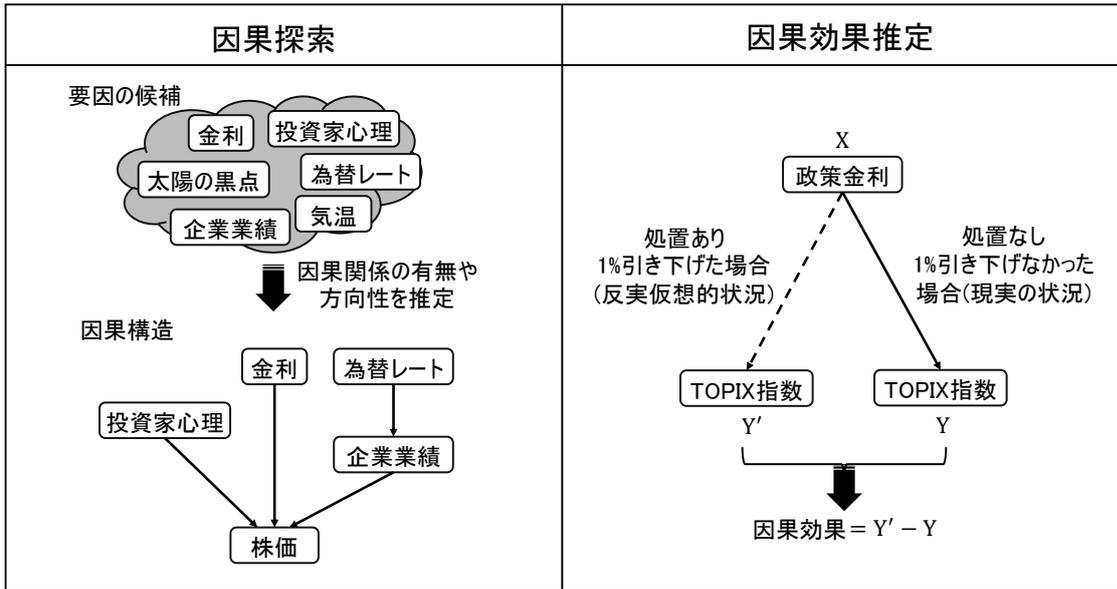
## 2.1 因果探索と因果効果推定

因果推論は、その分析目的に応じて主に二つのアプローチに大別される。第一に、因果探索 (causal discovery) は、変数間の因果的依存関係が未知の場合に、その構造を体系的に表現し自動的に探索するアプローチである。第二に、因果効果推定 (causal effect estimation) は、既知の因果関係に基づき、特定の介入や処置が結果変数に及ぼす定量的影響を推定するアプローチである。両者は補完的な関係にあり、特に金融市場のような高次元かつ動的な環境では、両者の適切な使い分けが重要となる。

たとえば、株式市場における複数の要因 (金利、為替レート、企業業績、投資家心理指標など) と株価変動との関係を調査する場合を考える (図表 2)。因果探索の段階では、過去の観測データに基づき、「金利が株価に影響を与えるのか」「為替変動は業績を介して株価に影響するのか」といった因果関係の有無や方向性を探索する。この段階では因果構造は既知ではなく、複数の変数間のネットワーク構造の探索が焦点となる。一方、因果効果推定では、因果構造が既に定まっている前提のもと、特定の介入の効果を推定する。たとえば「政策金利を 1% 引き下げた場合、TOPIX 指数は平均してどの程度上昇するか」を推定する場面である。この場合、実際に介入が行われたかのような反実仮想的状況を模擬し、その因果効果を定量的に評価する。

このように、因果探索は因果構造に関する仮説形成のために用い、因果効果推定はその仮説に基づき具体的な政策や意思決定の効果を評価するものである。金融分野における因果推論の応用では、まず因果探索によりモデル構造を同定し、その上で因果効果推定により具体的な行動の有効性やリスクを定量化するという、段階的なアプローチが有効である。

図表2



出所) 筆者作成

## 2.2 統計的因果推論、因果AI、自然言語処理に基づく因果推論

近年、因果推論の研究領域においては、統計学的手法を基盤とする「統計的因果推論 (Statistical Causal Inference)」と、機械学習技術を応用した「因果 AI (Causal AI)」という二つの主要な潮流が形成されている。さらに、近年急速に発展している新たな潮流として、自然言語処理 (Natural Language Processing, NLP) に基づく因果推論 (NLP-based Causal Inference) が注目されている。これら三者の比較を図表3に示す。

まず、統計的因果推論とは、観察データあるいは実験データに基づいて、ある介入が結果に与える因果的影響を推定・検証するための統計学的手法の総称である。Rubin の因果モデル (Rubin Causal Model) および Pearl の構造的因果モデル (Structural Causal Model, SCM) に理論的基盤を置き、無作為割り当てや共変量による交絡制御などの明示的な仮定のもとで因果関係を識別・推定する。代表的な手法としては、差の差分析 (Difference-in-Differences, DID)、傾向スコア法、操作変数法 (Instrumental Variable Method, IV 法)、回帰不連続デザイン (Regression Discontinuity Design, RDD)、および構造推定に基づく因果探索手法 (例: LiNGAM) などが挙げられる。

次に、因果 AI とは、機械学習や深層学習のアルゴリズムを活用して、因果構造の発見、因果効果の推定、反実仮定の生成といった因果推論的タスクを遂行する AI 技術群を指す。従来の予測 AI (Predictive AI) は相関に基づく予測性能の向上を主目的としていたのに対し、因果 AI は介入や反実仮定の推論を可能とする点で本質的に異なる。具体的には、データ駆動的な因果構造学習 (例: NOTEARS)、ニューラルネットワークを用いた介入効果の推定 (例: DragonNet)、さらには深層学習との融合による意思決定最適化など、多様な技術的展開が進められている。

最後に、自然言語処理（NLP）に基づく因果推論は、論文、ニュース記事、SNS 投稿といったテキストデータから因果関係を抽出・推定・構造化することを目的とした技術である。典型的には、因果的な言語表現（例：“X causes Y”、“Y is due to X”）の検出、言語モデルを用いた因果関係の識別、因果知識グラフの構築、さらには生成 AI による反実仮想文の生成などが含まれる。手法的には、ルールベースの情報抽出から、BERT や GPT などの言語モデルを用いた深層学習型アプローチに至るまで、多様な技術が併存している。

図表3

	統計的因果推論	因果 AI	NLP ペース因果推論
目的	数量データにおける因果探索・因果効果推定	複雑・高次元データへの因果推論の拡張	テキストから因果関係の発見・理解
入力データ	数値指標などの構造化データ	構造化データと非構造化データ	テキスト（文書、対話、SNS など）
モデルの解釈性	明示的・可解なモデル（回帰、確率モデル等）	非線形・ブラックボックス的モデル	自然言語による明示的・可解な因果関係提示
理論基盤	反実仮想モデル、構造的因果モデル	深層学習、最適化理論との融合	自然言語処理技術の応用

出所) 筆者作成

### 3. 金融分野における統計的因果推論の応用

統計的因果推論は、金融市場や制度の変化が経済主体に及ぼす影響を定量的に評価する有効な手段として、金融分野で広く活用されている。特に、観察データの特性やその発生構造の探求に重きを置く実証金融研究において、単なる相関ではなく因果関係を特定するための重要な方法論として確立されている。以下では、金融分野における統計的因果推論の具体的な応用事例のごく一部を紹介する。

#### 3.1 金融政策の効果測定：操作変数法（IV法）

中央銀行による政策金利の変更が実体経済や金融市場に与える影響は、因果推論の代表的な研究対象である。しかし、政策金利には内生性が伴うため、単純な回帰分析ではバイアスが生じてしまう。この課題を解決するため、操作変数法（IV法）が活用されている。Kuttner（2001）は、FOMC 声明発表前の連邦ファンド先物価格から算出した「予想外の政策金利変化（monetary policy shocks）」を操作変数として用い、金利変更が株価に与える因果効果を推定した。

### 3.2 ガバナンス制度改革と企業業績：差の差分分析（DID）

制度変更が企業行動に与える影響を測定する手法として、差の差分分析（DID）が効果的である。Gompers et al. (2003) は、企業統治の強化が株主リターンに与える影響を分析した研究において、州ごとのガバナンス規制変更を外生的ショックとして扱い、DID を用いて制度導入前後の変化を比較検証した。

### 3.3 金融資産間の因果構造探索：LiNGAM

リスク管理とポートフォリオ構築においても、因果構造を考慮したアプローチが進展している。金融資産間の構造的因果を特定することで、リスク要因の源泉を明らかにし、ヘッジ戦略の最適化やストレステストの設計が可能となる。最新の研究では、LiNGAM (Shimizu et al., 2006) などの因果探索手法を活用して、株式やマクロ指標間の因果構造を抽出する取り組みが報告されている (Yamamoto, 2020)。

## 4. 金融分野における因果AIの応用

因果 AI は、統計的因果推論と機械学習を融合することで、意思決定に不可欠な課題に対する新たな分析枠組みを提供している (Hurwitz & Thompson, 2023)。従来の統計的因果推論が構造化された数値データを主な対象としていたのに対し、因果 AI は機械学習との融合により、テキスト・画像・音声などの非構造化データを含む、高次元で複雑なマルチモーダルデータまで扱えるようになった。この技術的進展を背景に、因果 AI の金融分野への応用も急速に広がっている。以下では、代表的な研究領域とその成果を概観する。

### 4.1 マルチモーダル因果学習による金融予測

Zhang et al. (2025) は、マクロ経済イベントに対する市場反応を予測する因果 AI フレームワーク「CAMEF」を提案した。この手法は、政策声明などのテキストと時系列金融データを統合し、因果学習モジュールと大規模言語モデル (LLM) を用いて反実仮想的シナリオを生成・評価する。米国の5種類の資産（株式、債券など）を対象とした実証分析では、従来の深層学習 Transformer ベースの手法を上回る予測性能を示した。

### 4.2 非定常時系列における因果構造発見

Sadeghi et al. (2023) は、金融時系列の非定常性と時間遅延構造を考慮した因果探索フレームワーク「CD-NOTS」を提案した。GDP・株価・金利など複数のマクロ・市場変数から時变的かつ非定常な因果構造を抽出し、要因ベースの投資判断やポートフォリオ構築への応用可能性を示した。特に、因果グラフに基づく意思決定支援の基盤構築に貢献している。

### 4.3 因果特徴選択によるリターン予測モデル

Oliveira et al. (2024) は、DynoTEARS や改良型 VAR-LiNGAM など

の因果探索アルゴリズムを用いて、株式・ETFのリターン予測モデルにおける説明要因となる特徴量の選択を最適化した。金融危機期などの高不確実性環境下で、因果的特徴選択に基づくモデルは非因果的アプローチより高い安定性と汎化性能を示し、過剰適合も抑制できることが明らかになった。

#### 4.4 株価間の時間的因果ネットワーク

Li et al. (2024) の「CausalStock」フレームワークは、ニュース記事から株価間の時間的因果ネットワークを構築し、株価予測モデルに統合した。ラグ依存構造を考慮したニュースベースの因果探索と Functional Causal Model による統合的処理により、米国・中国・日本・英国を含む6つの主要市場で多銘柄同時予測の精度を向上させた。

#### 4.5 説明可能なAI (XAI) の金融分野への応用

機械学習技術の急速な発展に伴い、その判断プロセスの「ブラックボックス化」による不透明性や説明責任の欠如が課題となっている。この課題に対し、機械学習モデルの判断根拠を人間が理解できる形で提示する説明可能なAI (Explainable AI, XAI) が注目を集めている。一方、因果AIは介入や反実仮想といった因果推論の機能をAIに組み込み、因果理論に基づく説明性の構築を目指している。XAIがモデルの挙動の可視化と理解可能性を追求するのに対し、因果AIはより構造的で実践的な意思決定支援のための説明性を目指している。

両アプローチは「説明性の向上」という目的を共有しており、近年では因果AIをXAIの有力な手法の一つとする見方も増えている。XAIには因果推論とは異なる説明性実現手法もあり、代表的なものが特徴量帰属法 (Feature Attribution) である。これは入力特徴量のモデル出力への影響度を定量化し、予測結果への各要因の寄与度を説明する。特に、ゲーム理論に基づく特徴量帰属法 SHAP (SHapley Additive exPlanations) は、金融分野で以下のような実践的応用が進んでいる。

- 原油価格の変動要因分析 (金田他, 2022)
- 金融システムにおけるリスク情報要因の特定 (Bluwstein et al., 2023)
- 企業の格付け分類モデルにおける要因分析 (橋本他, 2023)

### 5. 金融分野における自然言語処理に基づく因果推論の応用

#### 5.1 なぜ100年に一度の金融危機の要因がわかるのか

統計的な分析に必要な十分なデータが存在しない極めて稀な現象—たとえば「100年に一度の金融危機」においても、専門家や一般の人々はその要因をある程度推定することができる。人間は、観察、介入、反事実という三層の認知能力 (図表1) を駆使することで、データが不十分な場合でも、複雑な現象の因果関係を構築することが可能である。

統計的因果推論や因果AIが対象とするのは、比較的安定した再現性のある

因果関係であり、十分なデータがあれば統計的手法によって検証できる。これを「統計的因果」と呼ぶ。たとえば「物体に力を加えると運動する」といった自然科学の第一原理に基づく因果関係が典型例である。しかし、経済現象のように人間の行動が深く関わる領域では、統計的因果だけでは事象を説明することが困難である。その主な理由は、人間が出来事をどう認知し、それにどう反応するかという人間の認知と行動ルール自体が因果構造の中核をなすためである。こうした因果関係は状況や文脈によって変化しやすく、自然科学のような客観的・普遍的な因果系列を統計的に導き出すことは難しい。人間は自らの観察や経験に基づいて現象を理解しようとし、その際には状況に応じた因果メカニズムの把握が重視され、実践的・具体的な文脈に即した因果関係が追求される。このような因果の理解を「経験的因果」と呼ぶ。

統計的因果と経験的因果は対立するものではなく、むしろ相補的な関係にある。統計的因果推論は経験的因果の知見を数理的に定式化しようとする試みであり、経験的因果は統計的推論の前提や解釈の妥当性を支える基盤となる。両者を統合することで、因果推論の信頼性と説明力が高まり、より説得力のある理解が可能となる。この関係性は西洋医学と東洋医学の対比に似ている。西洋医学は実験や統計に基づく定量的・科学的アプローチを重視し、再現性のある知識体系を構築してきた。これは統計的因果に相当する。一方、東洋医学は患者個々の症状や体質に基づく全体論的・経験的アプローチをとり、経験的因果に近い。いずれか一方だけでは捉えきれない現象に対して、両者の知見を融合することでより包括的な理解と治療が可能となる。

同様の関係は、経済学における計量経済学とナラティブ経済学の間にも見られる。計量経済学は統計モデルや数理的な手法により因果関係を定量的に分析する。一方、ナラティブ経済学は物語や歴史的な文脈に着目し、経済主体の行動や意思決定の背後にある意味や動機を質的に解明しようとする。両者を組み合わせることで、単なるデータの相関を超えて、現象の背後にある人間的・社会的意味までを含めた深い理解が実現される。金融分野では、株価の変動要因や投資リターンの予測において統計的因果推論が中心的な役割を果たしているが、それだけでは市場参加者の複雑な行動を捉えきれない。実際には、トレーダーや投資家の行動、意思決定プロセスを質的に観察し、取引パターンや市場心理を経験的に理解することが求められている。こうした統計的因果と経験的因果の両輪によって、経済や金融といった複雑系の因果構造に対するより深い洞察が可能となるのである。

## 5.2 自然言語処理による経済的因果連鎖の構築と検索

経験的因果の知識は、人々が日常的に使用する自然言語によるテキストデータの中に記述されている。近年、自然言語処理（NLP）技術を用いて、大量のテキストデータから因果情報を機械的に抽出・活用する取り組みが進展している。鳥澤（2003）や乾他（2004）の研究をはじめとして、因果関係情報を扱う技術の研究開発も活発に行われている。

本節では、経済・金融分野に特化して開発した因果連鎖の検索システムの概要とその応用例を紹介する。和泉他（2021）は、経済関連のテキストデータ

から因果関係を抽出・データベース化し、特定のフレーズに関連する因果連鎖を検索できるシステムを開発した。このシステムにより、ユーザーは入力した語句に対する因果連鎖を確認・編集でき、経済的な波及効果とその要因を把握することができる。

### 5.2.1 経済的因果関係の抽出とデータベース構築

和泉他 (2021) では、上場企業の決算短信に記述された情報から、手がかり表現を用いて因果関係を抽出した。

- 使用したテキストデータ：2012年10月から2024年10月に発行された決算短信テキスト
- 抽出された因果関係数：約100万件

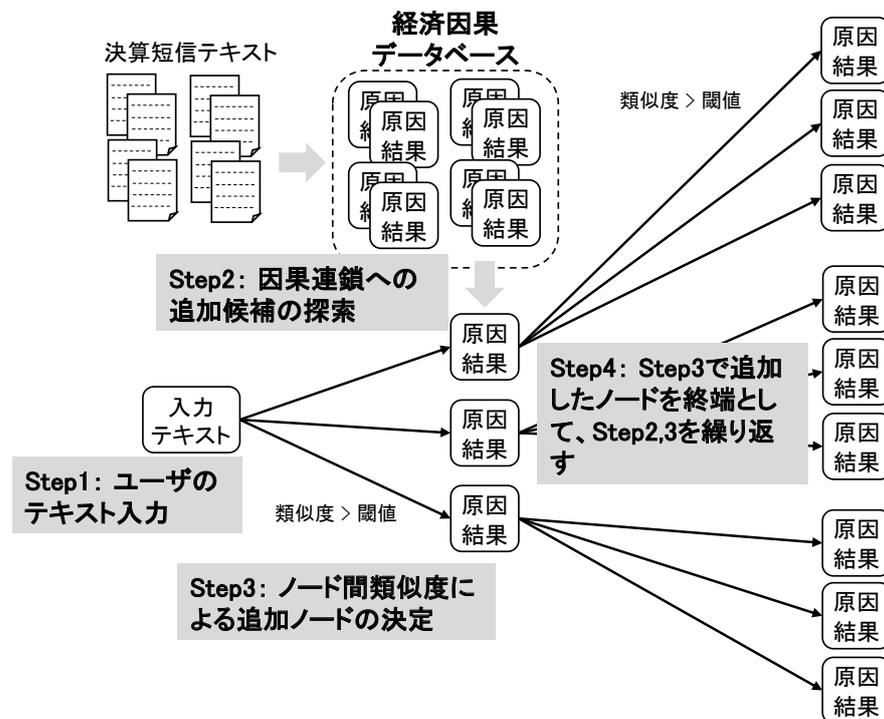
これらの因果関係は、発行日や銘柄情報とともにデータベースに保存され、検索・分析に活用される。

### 5.2.2 因果連鎖の構築アルゴリズム

因果連鎖の構築は、以下の四つのステップで実行する (図表4)。

1. ユーザーによるフレーズの入力 (最初の終端ノードの設定)
2. 入力された終端ノードと類似する因果関係の選択
3. ノード間の類似度を計算し、閾値 $\alpha$ に基づいてネットワークを拡張
4. 新たに追加されたノードを次の終端ノードとして、ステップ2・3を繰り返す

図表4



出所) 和泉他(2021)より筆者作成

因果連鎖構築アルゴリズムに基づき、ユーザーが因果関係を確認・編集できる検索システムを実装した（図表5）。このシステムでは、ユーザーが検索の起点となるテキストを入力し、「波及効果」または「要因検索」を選択して検索を実行すると、関連性の高い因果関係が表示される。

図表5



出所) 因果連鎖探索の試作システム <https://socsim.t.u-tokyo.ac.jp> の「公開ツール」-「因果チェーン検索」-「因果チェーン検索サービス」

### 5.2.3 経済的因果連鎖検索の応用例

和泉他 (2021) で提案されたような因果連鎖検索の手法を、経済金融分野に応用した事例を紹介する。

#### 経済変動の企業への影響分析

令和4年度中小企業実態調査（デロイトトーマツコンサルティング合同会社、2023）では、感染症の流行、自然災害、資源価格の高騰などの経済社会上的変動が中小企業に及ぼす波及効果を分析した。これらの影響は、特定の企業だけでなく、サプライチェーンの断絶、風評被害、自粛の連鎖を通じて広範に波及する。このような複雑な影響構造を把握するには、単一の事象だけでなく、その因果的な派生を追跡する必要がある。本調査では、因果連鎖検索の手法として、決算短信のテキストと日経新聞記事を階層的に組み合わせるアプローチを採用した。分析の結果、「感染症の拡大」から「外出機会の減少」といったネガティブな影響から、「家飲み需要の増加」といったポジティブな派生效果まで、さらには製造業における「Mixed Reality (MR) 技術の活用」といった新たな経済トレンドも特定された。この手法により、実務上重要な因果の連鎖を発見し、支援対象の特定や政策立案に活用できることが実証された。

#### 株価へのニュースインパクト分析

因果連鎖検索は、ニュースが金融市場に与える影響を分析する上で有効な手法であり、ニュースの解釈と市場反応の関係を定量的に捉える基盤となる。

Izumi et al. (2020) では、小麦価格に関する二つのニュース事例を用いて、関連企業の株価への影響を実証的に検証した。2018年7月24日の「フランスで小麦減産見込み」や2018年9月6日「ロシアが小麦の輸出制限をしない」というニュースで、市場はニュースの背景にある遠因に注目し、因果連鎖上の企業の株価に影響が及んだことを明らかにした。この手法は、ニュースに基づく株価変動の因果構造の理解に有効であり、関連企業の選定や市場反応の予測精度向上に貢献する。

#### 株価におけるリード・ラグ効果分析

Nakagawa et al. (2019) では、因果連鎖を用いて、株価におけるリード・ラグ効果（ある先行銘柄のリターンが時間差を伴って別の遅行銘柄のリターンに影響を与える関係）を推定した。具体的には、因果連鎖における「原因」企業群に顕著な株価変動が生じた際に、その影響が「結果」企業群へとリード・ラグ的に波及するかを実証的に分析した。その結果、この手法に基づく投資戦略が有意な収益性を示し、日本株式市場において因果的に結びついた企業間での株価予測可能性が存在することが確認された。

## 6. 経済金融分野における因果推論の将来

### 6.1 大規模言語モデルと統計的因果推論の融合

近年、大規模言語モデル（Large Language Models, LLM）の急速な進展により、従来の課題を克服し、因果推論タスクへの応用可能性が注目されている。統計的因果推論は観察データから因果関係を明らかにする強力な枠組みだが、現実世界の複雑な現象に対して意味のある一貫した因果モデルを構築するには、ドメイン専門家の知識を制約として導入することが不可欠である。しかし、専門知識を体系的かつ網羅的に取得することは困難であり、この点が実用上の主要な制約となっている。

このような課題に対し、LLMと統計的因果推論の統合による新たなアプローチが期待されている（Takayama et al., 2025 および三内他, 2025）。ただし、実用化には、LLMの出力の信頼性向上および統計的因果構造との相互作用に関する理論的・実証的理解が不可欠である。LLMは本質的に確率的パターン認識に基づいており、相関と因果の混同、専門用語の多い領域や非英語環境での誤推論の増加、言語表現やドメインの変化に対する脆弱性といった構造的限界が指摘されている（Takayanagi et al., 2024）。LLMの出力は因果構造の本質的理解というよりも、因果情報を含む文章を表面的に再現するような生成にとどまる傾向が強い。

より精度の高い因果推論を実現するには、LLMと統計的因果推論を統合する新たなフレームワークの構築が必要である。そのためには、構造化された因果モデル学習との連携を通じて、自然言語処理と因果推論の相互補完的活用を可能にする設計が求められる。

## 6.2 反実仮想としてのエージェントシミュレーション

社会経済分野において、反実仮想的状況を統計的手法や自然言語処理によって観察データから推定するアプローチには限界がある。特に、創発的で予測困難な現象や制度変更に伴う非線形的影響の把握には、既存のモデル構造に依存する従来手法では十分に対応できない。このような背景から、複数の自律的意思決定主体（エージェント）で構成されるマルチエージェントシミュレーション（Multi-Agent Simulation: MAS）が注目されている。MAS は実世界の社会経済構造を模倣し、制度変更や介入策に対する反実仮想的な影響を直接的に再現・評価できる枠組みとして期待される。

水田（2024）は、人工市場と呼ばれるエージェントベース金融市場シミュレーションに着目し、呼値刻み変更、レバレッジ規制、空売り規制といった実市場における制度導入の影響を評価した研究などを紹介している。反実仮想的な「ありえた副作用」の抽出および政策設計への応用可能性を示し、制度介入前に市場構造の変容や予期せぬ副作用を検証する手段としての有効性を主張している。

森下ら（2025）は、反実仮想的シナリオを仮想空間上で再現する手法として、LLM エージェントを活用した経済シミュレーション環境「EconGrowthAgent」を提案した。本環境は、マクロ経済理論に基づき、家計や企業などの経済主体の意思決定過程を大規模言語モデルで模倣し、それらの相互作用を通じて生産活動の動学を再現する。100 体のエージェントによる 20 年間のシミュレーションでは、経済成長とその周辺現象が再現可能であることが示され、モデルの妥当性が検証された。さらに、「超小さな政府への政権交代」や「地球滅亡級の隕石接近」といった現実では観察不可能な極端なシナリオを仮想的に設定し、その経済的影響を分析することで、反実仮想を直接検証するプラットフォームとしての有効性が確認された。

これらの研究はいずれも、「反実仮想を直接検証・予測するツール」として機能する点で共通している。今後、マルチエージェントシミュレーションは、人間集団の意識や行動の変容を仮想的に再現し、政策導入や社会状況変化に対する世論や行動反応を事前に推定するプラットフォームとして、因果関係をより精緻に検証する可能性を示している。

## 7. まとめ

本稿では、金融分野における因果推論の方法論を、統計的因果と経験的因果の二つに分類し、それぞれの理論的背景と応用可能性について概説した。また、統計的因果推論、因果 AI、自然言語処理を用いた因果推論の手法とその適用例を取り上げ、今後の展望についても論じた。

今後の応用が期待される領域としては、高頻度取引市場における価格変動の因果連鎖の解明や、金融政策の波及効果における統計的因果と市場心理との相互作用の分析が挙げられる。また、ESG（環境・社会・ガバナンス）投資では、企業の ESG 対応が中長期的に企業価値へ与える影響を統計的手法により

評価する一方で、個別企業の事例研究を通じてその意思決定プロセスやステークホルダーとの関係性を理解する定性的分析の重要性も増している。

統計的因果と経験的因果は独立したアプローチだが、相互に補完し合うことで、金融経済の複雑な因果構造を多面的かつ実践的に理解するための有力な手段となる。たとえば、計量分析によって検出されたマーケット・アノマリーの背後にある投資家行動や意思決定の原理を、エージェントベース・シミュレーションや自然言語処理などの経験的手法を通じて解明することが可能となる。両者を統合することで、因果推論はより実践的かつ説得力のある分析枠組みへと発展しうる。今後の因果推論研究においては、この統合的視座のもとで、多様な方法論を融合できる柔軟な手法の構築と金融分野での実践的な応用が求められる。

### 参考文献

- Bluwstein, K., Buckmann, M., Joseph, A., Kapadia, S., & Şimşek, Ö. (2023). Credit growth, the yield curve and financial crisis prediction: Evidence from a machine learning approach. *Journal of International Economics*, 145.
- Dessaint, O., et al. (2024). Does alternative data improve financial forecasting? The horizon effect. *The Journal of Finance*, 79(3), 2237-2287.
- Gompers, P., Ishii, J., & Metrick, A. (2003). Corporate governance and equity prices. *Quarterly Journal of Economics*, 118(1), 107-156.
- Hoover, K. D. (2018). Causality in economics and econometrics. In *The New Palgrave Dictionary of Economics* (pp. 1446-1457). London: Palgrave Macmillan UK.
- Hume, D. (1785). *Essays, moral, political, and literary* (E. F. Miller, Ed., 1985). Indianapolis: Liberty Press.
- Hurwitz, J. S., & Thompson, J. K. (2023). *Causal artificial intelligence: The next step in effective business AI*. Wiley.
- Izumi, K., Suda, S., & Sakaji, H. (2020). Economic news impact analysis using causal-chain search from textural data. In *The AAAI-20 Workshop on Knowledge Discovery from Unstructured Data in Financial Services*, New York, USA.
- Kuttner, K. N. (2001). Monetary policy surprises and interest rates: Evidence from the Fed funds futures market. *Journal of Monetary Economics*, 47(3), 523-544.
- Li, S., Sun, Y., Lin, Y., Gao, X., Shang, S., & Yan, R. (2024). CausalStock: Deep end-to-end causal discovery for news-driven multi-stock movement prediction. In *NeurIPS 2024*.
- Nakagawa, K., Sashida, S., Sakaji, H., & Izumi, K. (2019). Economic causal chain and predictable stock returns. In *7th International Conference on Smart Computing and Artificial Intelligence (SCAI 2019)*, 655-660.
- Oliveira, D., Lu, Y., Lin, X., Cucuringu, M., & Fujita, A. (2024). Causality-inspired models for financial time series forecasting. SSRN. <https://ssrn.com/abstract=4971119>
- Pearl, J. & Mackenzie, D. (2018). *The book of why: The new science of cause and effect*. Basic Book. (栗田昭平訳, 『因果推論の科学—「なぜ?」の問いにどう答えるか』, 草思社, 2019年)
- Sadeghi, A., Gopal, A., & Fesanghary, M. (2023). Causal discovery in financial

- markets: A framework for nonstationary time-series data. SSRN. <https://ssrn.com/abstract=4678484>
- Shimizu, S., Hoyer, P. O., Hyvärinen, A., & Kerminen, A. (2006). A linear non-Gaussian acyclic model for causal discovery. *Journal of Machine Learning Research*, 7, 2003-2030.
- Smith, A. (1776). *An inquiry into the nature and causes of the wealth of nations*. London: W. Strahan and T. Cadell. (アダム・スミス『国富論：国の豊かさの本質と原因についての研究』山岡洋一訳 日本経済新聞出版社 2007年)
- Takayama, M., Okuda, T., Pham, T., Ikenoue, T., Fukuma, S., Shimizu, S., & Sannai, A. (2025). Integrating large language models in causal discovery: A statistical causal approach. *Transactions on Machine Learning Research*, 5.
- Takayanagi, T., Suzuki, M., Kobayashi, R., Sakaji, H., & Izumi, K. (2024). Is ChatGPT the future of causal text mining? A comprehensive evaluation and analysis. In *2024 IEEE International Conference on Big Data (BigData)*, 6651-6660.
- Yamamoto, R. (2020). Causal analysis of macro-financial linkages using LiNGAM. *Journal of Financial Econometrics*, 18(2), 348-374.
- Zhang, Y., Yang, W., Wang, J., Ma, Q., & Xiong, J. (2025). CAMEF: Causal-augmented multi-modality event-driven financial forecasting by integrating time series patterns and salient macroeconomic announcements. In *KDD 2025* (to appear).
- 和泉潔・坂地泰紀・松島裕康 (2021)『金融・経済分析のためのテキストマイニング』岩波書店。
- 乾孝司・乾健太郎・松本裕治 (2004)「接続標識「ため」に基づく文書集合からの因果関係知識の自動獲得」『情報処理学会論文誌』45(3), pp.919-933.
- 金田規靖・木全友則・平木一浩・松栄共紘 (2022)「SHAP を用いた機械学習モデルの解釈—原油価格の変動要因分析を例に—」日本銀行金融研究所 [https://www.imes.boj.or.jp/jp/conference/finance/2022\\_slides/1111finws\\_slide2.pdf](https://www.imes.boj.or.jp/jp/conference/finance/2022_slides/1111finws_slide2.pdf)
- 三内顕義・高山正行・清水昌平 (2025)「大規模言語モデルを活用した統計的因果探索の新展開—統計的因果プロンプティングによる専門知識とデータの融合—」『SBI 金融経済研究所 所報』vol.8 pp.46-61.
- デロイト トーマツ コンサルティング合同会社 (2023). 令和4年度中小企業実態調査事業「中小企業の実態把握等のためのデータ利活用に関する委託調査」<https://www.meti.go.jp/meti-lib/report/2022FY/000326.pdf>
- 鳥澤健太郎 (2003)「[常識的] 推論規則のコーパスからの自動抽出」『言語処理学会 第9回年次大会 発表論文集』pp.318-321.
- 橋本龍一郎・三浦翔・吉崎康則 (2023)「格付け分類モデルにおける機械学習の応用：機械学習の説明可能性を高める手法」日本銀行ワーキングペーパーシリーズ
- 水田孝信 (2024)「人工市場：金融市場のコンピュータ・シミュレーション」『SBI 金融経済研究所 所報』vol.5 pp.54-66.
- 森下皓文・角掛正弥・山口篤季・永塚光一・友成光・森尾学・今一修・十河泰弘 (2025)「EconGrowthAgent: LLM エージェントと経済成長理論に基づくマクロ経済シミュレーション」『人工知能学会全国大会論文集 第39回』