視点の違いに着目した金融因果推論の高度化

市瀬 龍太郎｜東京科学大学 工学院 教授
許 子微｜東京科学大学 工学院 助教
陳 穎｜東京科学大学 工学院 博士課程在籍
井上 光太郎｜東京科学大学 工学院 教授

市瀬 龍太郎

1995 年東京工業大学卒業。2000 年東京工業大学博士課程修了。博士（工学）。国立情報学研究所助手、助教授、准教授、スタンフォード大学言語情報研究所客員研究員、文部科学省学術調査官、産業技術総合研究所招聘研究員、東京工業大学教授などを経て、現在、東京科学大学 工学院 教授。専門は人工知能。

要約

因果関係を理解することは、説明可能な AI の実現、特に経済分野における意思決定にとって極めて重要である。しかし、実世界においては、因果関係の同定は容易ではなく、多様な事象データの観測が困難であるという「可観測性の問題」によって、因果関係の把握は困難な問題となっている。本稿では、この課題に対処するために、膨大に存在するテキストから経済専門家の視点を反映した因果関係を取り出し、それを整理した因果知識グラフを自動構築する機械学習フレームワークについて述べる。本フレームワークには、特定の視点に基づき表現された因果推論を抽出するためのデータマイニングアルゴリズムが組み込まれている。実際の市場データを用いて評価した結果、統計的に有意かつ高品質な因果推論パターンが明らかとなり、その頑健性が裏付けられた。これは、視点を考慮した因果知識グラフが、因果推論、経済モデリング、政策分析の高度化に貢献し、多様な専門家の視点を通して経済現象へのより深い洞察を提供し得ることを示している。さらに、経営者の過信に起因する視点バイアスの違いを明らかにする新たなデータセット CC-BizEnv を生成するフレームワークについても述べる。それを用いて、上場企業の経営者に内在する認知バイアスを定量化することができる。

キーワード：因果知識グラフ、経済因果性、視点表現、機械学習、データマイニング、自信過剰

1．はじめに

因果関係を示す際に用いられる事例の多くは、理論的な仮定に強く依存しているため、非現実的で過度に単純化され、実際の状況を十分に反映していないことが多い。この問題は、観察された情報からだけでは因果関係を特定・観測することが困難であることに起因しており、一般に「可観測性の問題（observability problem）」として知られている（Lane, 2020）。因果関係の可観測性を高めるための有効な手段として、膨大に存在するテキストを利用する方法がある。テキストから因果関係を抽出し、整理したものとして、因果

知識グラフがある。因果知識グラフは、構造化された情報を格納し、複雑な関係を可視化する手法として注目されている。例えば、Wikidata（Vrandecic and Krötzsch, 2014）は汎用的な常識的知識を提供し、ICEWS（O' Brien, 2010）は国家や政治家間の政治的イベントや相互作用を記録している。また、FinCaKG（Xu et al., 2025）は、上場企業の年次報告書に基づき、経済領域に特化した因果関係を記録している。

経済分野においては、同一の状況下であっても、それぞれのエージェントが企業パフォーマンスに対して異なる評価を下すことがある。「視点（standpoint）」とは、エージェントの評価的態度を構造的に表現したものであり、そのエージェントが妥当または許容可能とみなす語彙や言語的解釈の集合を捉えたものである（Bennett, 2011）。視点を表現することは、異なるエージェントが、経済現象にどのように反応するかをモデル化する上で極めて重要であり、政策立案、市場予測、リスク評価に資する。さらに、視点が明確に定義されることで、異なる条件下における経済行動のシミュレーション精度が高まり、より豊かな洞察と頑健な結論を導くことが可能となる。

本稿では、異なる視点を持つエージェントが、異なる因果推論を行うことに着目し、それをどのように明らかにするのかについて議論を行う。そのために、テキスト情報から因果関係を抽出し、そこからどのように視点の違いに応じた因果関係を発見するかについて説明をする。第 2 節で、テキストから因果関係を抽出する方法、因果関係を整理して知識グラフにする方法、因果推論において視点の違いを抽出する既存研究について概観する。次に、第 3 節で、機械学習技術を利用することにより、経済専門家の視点を表現する因果知識グラフを自動生成するフレームワーク FinCaKG を説明する。続く第 4 節では、この因果知識グラフを利用し、専門家の視点に応じた因果推論を抽出するためのデータマイニングアルゴリズム ETE-FinCa を紹介する。さらに、実際の市場データを用いてアルゴリズムを評価した結果についても紹介する。第 5 節では、経営者の過信に起因する視点バイアスの違いを検証するための因果エンティティデータセット CC-BizEnv の生成フレームワークを提示する。そして、それを用いた上場企業の経営者における認知バイアスの定量化を行う手法、および、実験結果に基づき、経営者の過信傾向を捉える指標としての有効性についてについて議論する。最後の第 6 節で、本稿の結論および今後の展望について論ずる。

2. 関連研究

2.1 テキストからの因果関係の抽出

因果関係を整理して利用するために、本稿では、テキストから因果関係を抽出し、それを整理して知識グラフの構築を行う。テキストからの因果関係の抽出する方法は、大きく分けて、パターンマイニングアプローチ、機械学習アプローチ、生成的アプローチの 3 通りがある。以下、これらの手法を順に説明する。

2.1.1 パターンマイニングアプローチ

テキストに現れる因果関係は微妙かつ多様であるため、その特定は容易ではない。この課題に対処するため、因果関係を表す動詞、特定の構文構造、語彙的な手がかりなどの言語的パターンを用いて、因果関係を抽出するルールベースの手法が開発されてきた（Luo et al., 2016; Girju, 2003; Radinsky et al., 2012; Ali et al., 2021）。これらの手法では、特定のパターンに当てはまった場合に因果関係があるとして、関係の抽出を行う。さらに、これらの従来型のパターンに加えて、原因と結果のペアの出現確率に基づく統計的アプローチも利用されており、教師なしで因果関係を予測する手法も試みられている（Chang and Choi, 2004）。

2.1.2 機械学習アプローチ

暗黙的な因果関係を発見するためには、表層的なパターンだけでは十分ではない。機械学習手法では、表層的なパターンを超えた、深い意味の把握を試みる。このアプローチでは、因果関係の手がかりを特徴ベクトルとして表現し、分類、回帰、クラスタリングなどのアルゴリズムを用いてその意味を解釈する（Ali et al., 2021）。パターンベースの手法は明示的な特徴の抽出には有効であるが、機械学習は、これらの特徴から一般化を行うため、より微妙な因果関係の抽出に適している（Sorgente et al., 2013; Rink et al., 2010）。近年では、自動的に特徴を抽出できるという利点から、ニューラルネットワークを用いた深層学習モデルが注目を集めている。当初は、再帰型ニューラルネットワークや畳み込みニューラルネットワークが用いられたが、これらは因果構造の抽出において、効果が限定的であり（Elman, 1990; LeCun et al., 1998）、より特化したアーキテクチャの研究が進められてきた（Yin et al., 2017）。近年では、汎用的な関係抽出モデルが因果関係の発見のために応用されている。そのようなものとして、REBEL（Huguet Cabot and Navigli., 2021）、UniRel（Tang et al., 2022）、ReLiK（Orlando et al., 2024）が挙げられる。REBEL は自己回帰型のデコーディング手法により、テキスト情報から、二つのエンティティとその関係を生成することができる。UniRel は、統一的な表現と自己注意機構を導入することで、エンティティと関係を同時に抽出することができる。ReLiK は、特定の戦略を用いることで、エンティティの関連付けと関係抽出を一度の処理で実現するようにし、効率性を向上させている。

2.1.3 生成的アプローチ

生成モデルは、従来の教師あり深層学習手法に代わり、柔軟な選択肢を提供する。特にアノテーションに多大なコストと時間を要する従来手法の問題を克服する手段として注目を集めている（Ye et al., 2022）。これらのモデルは、多様なタスクに容易に適応できるため、知識グラフ構築における構造的情報の抽出に有用である。生成アプローチには、主に、2 つの戦略が用いられている。第 1 の戦略は、タスク特化型のパイプライン戦略であり、生成モデルを順番に適用して、テキストからの因果関係の抽出に必要な、固有表現抽出、関係抽出、エンティティリンキングを行っていく。例えば、LSTM-CRF モデル（Lample et al., 2016; Straková et al., 2019）は、入力トークンに対する注意機構を用い

て、高精度な固有表現抽出を行う。また、KnowGL（Rossiello et al., 2023）は、エンティティのペアを検出し、ラベルや型、優先度付き関係を含む構造化ファクトを生成することで、生成モデルにより、情報抽出の複数のサブタスクを処理する。GENRE（De Cao et al., 2021）や、mGENRE（De Cao et al., 2022）は、文脈を考慮しながら、エンティティ名を自己回帰的に生成することで、エンティティリンキングを行う。第 2 の戦略はエンドツーエンド型の戦略を用い、テキスト情報から構造化されたエンティティ同士の関係を直接抽出する。DeepStruct（Wang et al., 2022）や UIE（Lu et al., 2022）は、事前学習と統一的なフレームワークを活用し、テキストをエンティティ同士の関係を含む構造的表現へと変換する。これらのアプローチは、新たなドメインへの適応が容易であり、多様な情報抽出タスクにおいて高い性能を示している。

2.2 因果関係知識グラフの構築

次に、抽出された関係を用いて、知識グラフの構築を行う。因果関係知識グラフを構築するためには、テキスト中で表現された原因と結果の関係を特定し、体系的に整理する作業を行う必要がある。初期の研究では、主に単語レベルの因果関係のペア抽出に焦点を当てていた。例えば、「bacteria（細菌）」が「disease（病気）」を引き起こすといった関係が扱われていた。Cause Effect Graph（Li et al., 2020）や、CauseNet（Heindorf et al., 2020）では、大規模な語彙レベルの因果ペアが収集され、テキスト中での出現頻度に基づいて重み付けが施されている。しかし、その後の研究では、因果関係が単語単位ではなく、より長いテキストのまとまり（スパン）として表現されている。例えば、「間違えた投資のために、破産した」という例では、「間違えた投資」という原因が、「破産した」という結果をもたらしており、文脈を含んだスパンベースの因果関係表現が必要となる。Frattini et al.（2023）は、スパンレベルの因果関係は、自然言語においてより頻繁に現れるだけでなく、情報量も豊富であることを報告している。近年の研究では、このようなスパンのペアを活用した知識グラフ構築へと焦点が移っている。FinCaKG（Xu et al., 2025）は、その代表例であり、因果スパンを構造化されたグラフとして接続することで、複雑な経済領域の因果ダイナミクスを捉えている。また、CausalBank（Li et al., 2020）のような他のモデルでも、文脈的な手がかりを取り入れた構造的表現の構築が試みられている。このように、単純で表層的なパターンマッチングから、スパンレベルへの移行は、より深い意味理解へと研究の方向性が深化していることを示している。

2.3 因果推論におけるバイアス選択

実際の因果関係の発見において、どの変数を因果の連鎖に含めるかの選択は極めて重要である。特に、特定の方向を持つバイアス（視点）に注目する場合には、この選択が重要となる。従来の研究の多くは、バイアスを最小化することに注目してきたが、ある研究では、特定の操作変数（Instrumental Variables）が、処置効果の推定において、逆にバイアスを増幅させることがあることを示している（Pearl, 2010）。伝統的な手法では、こうした影響を排除することを目指してきた。例えば、傾向スコアマッチング（Propensity Score Matching）（Rosenbaum

and Rubin, 1983）は、処置群と対照群の共変量をバランスさせることで、選択バイアスを減らそうとした。また、PC アルゴリズム（Spirtes et al., 2000）では、潜在的交絡因子が存在しないという仮定のもとで、条件付き独立性検定を行い、因果構造を取り出している。これらのアプローチとは対照的に、本稿ではバイアスの役割を再考する。すなわち、操作変数を排除するのではなく、あえてそれらを因果連鎖の中で明示的に特定することにより、専門家の視点に応じたバイアスを可視化し、その特徴を捉えることを目指した。このアプローチは、因果推論におけるバイアスの新たな表現と解釈の枠組みを提供することができる。

3．因果知識グラフ構築フレームワーク

3.1 概要

次に、因果知識グラフ FinCaKG（Xu et al., 2025）の構築手法について説明する。FinCaKG フレームワークの目的は、専門家レベルの知見と分野固有の信頼性を保ちながら、経済テキスト情報から因果関係の知識グラフを自動的に構築することである。この目標を達成するために、本研究では、各構成要素が明確かつ追跡可能な役割を担うモジュール型のフレームワークを設計した。このモジュール構造により、各処理段階での性能を個別に評価することが可能となり、最終的に生成される知識グラフの信頼性を担保することができる。

FinCaKG を作成する手法の概要を図表 1 に示す。図に示したように、FinCaKG は、以下の 5 つのモジュールから構成されている。

図表1　FinCaKG 構築のワークフロー

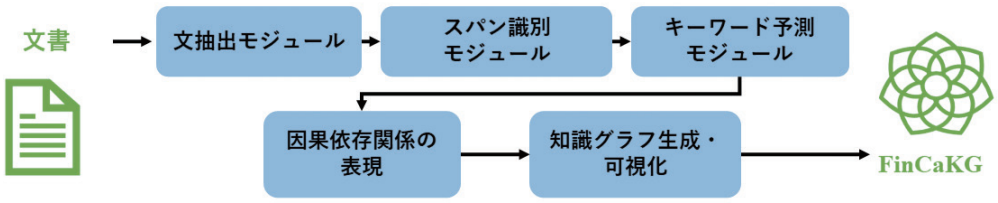

文抽出モジュール：因果関係を表現する文を特定して抽出する。
スパン識別モジュール：原因と結果に対応するテキストのスパンを検出する。
キーワード予測モジュール：検出されたスパンから主要な経済用語を抽出する。
因果依存関係の表現：原因と結果のキーワードペアを関連付けし、構造化された因果連鎖を形成する。
知識グラフ生成・可視化：最終的な知識グラフを構築して可視化する。

3.2 情報抽出手法

最初の 3 つの文抽出モジュール、スパン識別モジュール、キーワード予測モジュールでは、事前学習済み言語モデルを活用して、系列分類やトークン単位のラベル付けタスクを実行した。文の分類には BERT（Devlin et al.,

2019）を採用し、因果関係を含む文と含まない文を効果的に判別する。また、特定されたスパンからキーワードを予測するタスクには、XLM-Roberta（Conneau et al., 2020）を用いた。

これらのタスクの中でも、スパン識別が最も困難な課題である。特に、経済テキストにおける因果関係は微妙かつ複雑であるため、従来手法では十分な性能を発揮できない。例えば、次の文を考える。

> 中本氏は、1 日で 9,000 BTC を失い、12 億円の借金を抱えることになった（2014 年 2 月 10 日）

この文では、「1 日で 9,000 BTC を失った」が、原因 (cause) として特定され、「12 億円の借金を抱えることになった」が結果 (effect）として識別される。このような複雑な文に対処するため、私たちは、iLab-FinCau モデル（Xu et al., 2022）をスパン識別の中核として採用した。このモデルは、因果関係グラフの特徴を BERT 埋め込み層に統合することで、スパン識別能力を強化しており、グラフに基づく事前知識を活用することで、性能を向上させることができる。

3.3 因果依存関係の表現

主要なスパンとキーワードを特定した後に、これらのテキスト上の関係を構造化された因果知識グラフへと変換する。FinCaKG フレームワークでは、原因と結果のキーワードを、方向付けしたうえで、接続していく新たな関係表現の仕組みを導入した。この処理により、これまでのモジュールで得られた出力が統合され、FinCaKG 上で、意味的解釈が可能かつ、相互接続された因果関係が形成される。このようにして、FinCaKG フレームワークでは、自然言語処理とグラフベースの表現学習を統合することで、経済文書から、分野に特化した専門家の知識に基づく因果知識グラフを体系的に構築することができる。

4．視点に応じた因果関係の抽出

操作変数（IV: Instrumental Variable）は、反実仮想的なバイアスや交絡バイアスといった課題に対処するために、結果変数とは条件付きで独立でありながら、処置に影響を与える変数として機能する。経済分野における操作変数の構築は、通常、あらかじめ設計された合成操作変数に依存しており、その有効性は特定のアルゴリズムによって評価される。しかし、この従来の枠組みでは、より多様かつ具体的な操作変数が必要となる広範な課題には対応できない。本稿では、因果知識グラフに基づいた手法 ETE-FinCa（Chen et al., 2024）を説明する。この手法は、専門家の視点を最適化することにより、操作変数の情報源を構築し、専門的概念に基づいて操作変数を具体化するとともに、実際の経済データと統合して因果関係を解釈することができる。さらに、定義された高品質な操作変数は、二段階最小二乗法回帰（Two-Stage Least Squares Regression）において、処置変数と結果変数の間の因果関係を統計的に有意な形で同定することが可能である。

4.1 視点の抽出

「企業は誰のために存在するのか―株主のためか、それともステークホルダーのためか？」

この根本的な問いは、株式会社の登場以降、経済分野において、長年にわたり議論の的になってきた。Chen et al.（2024）は、経済テキストから構築した因果知識グラフを利用することで、辞書を利用した手法や数値指標を利用した手法といった伝統的なアプローチよりも、株主志向とステークホルダー志向という 2 つの視点を、より正確に判別できることを示した。因果知識グラフを利用することで、因果関係の論理的再構成や、認知連鎖に基づく推論が可能となり、企業の文脈に対するより深い知識を利用できることで、2つの立場の分類精度を向上させることができる。

異なるガバナンス視点を比較するために、因果知識グラフ C_{FinCaKG} 全体を、ステークホルダー指向の視点に基づく因果知識グラフ $C_{\text{ST-FinCaKG}}$ と、株主指向の視点に基づく因果知識グラフ $C_{\text{SH-FinCaKG}}$ の 2 つに分割する。そのために、「すべてのステークホルダーの利益のために事業を行う」と明言している企業を特定し、それらの企業が、過去 20 年間の年次報告書において開示したMD&A（経営者による財務状況および経営成績の分析）セクションから因果関係を抽出し、$C_{\text{ST-FinCaKG}}$ を構築した。同様に、「株主価値の最大化を主要な目標とする」企業に対して、$C_{\text{SH-FinCaKG}}$ を構築した。さらに、これら 2 つのサブグラフに含まれるすべての因果関係を統合し、全体グラフ C_{FinCaKG} を生成した。このグラフは、両視点の共通点および相違点を分析する際の基準として利用した。

図表2　ETE-FinCa における、因果変数の識別および解釈のためのワークフロー

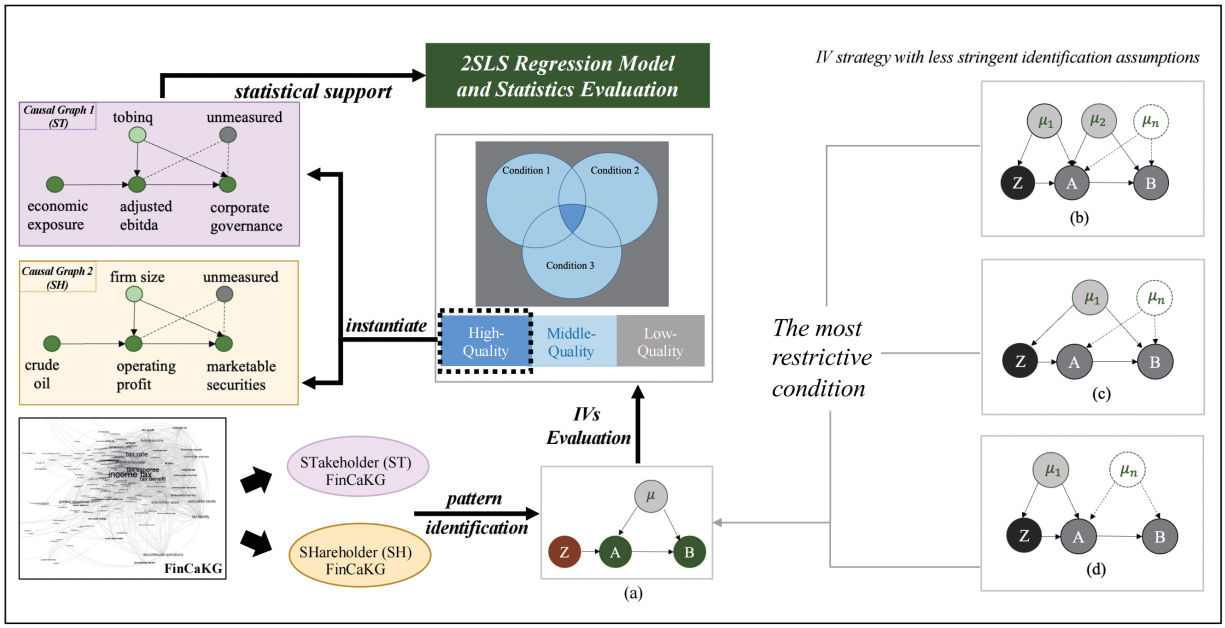

出所）Chen et al.(2024)中の図を許諾を得て改変。

4.2 内生性要因の選択

図表 2 は、因果変数の同定と解釈を行うための ETE-FinCa のワークフローを示している。図の右側（b ～ d）は、識別仮定を緩和した操作変数を提示している。これらのうち、我々は最も厳格な条件（a）を採用した。これは、変数 Z が変数 B と直接的に関連づけられる確率を最小化している。先行研究によれば、因果連鎖は 3 ホップを超えると、因果的意味を失う傾向がある（Xu et al., 2025）とされているため、3 ホップ以内の関係を「有効な論理的接続」と定義した。したがって、本タスクは以下のように定式化される：

> 「変数 A に関連し、かつ変数 B に 3 ホップ以内で関連しない操作変数 Z を因果連鎖の中から探索する」

このために、FinCaKG 上で「$Z \perp B \mid A$」の条件を満たすパターンを探索する深さ優先探索アルゴリズムを構築した。

図表 3 は、深さ優先探索アルゴリズムにおける因果変数識別の具体例を示している。破線の矢印は、因果連鎖内での遷移を表している。灰色でハイライトされたノードは、グラフから無効と判断されて削除されたノードであることを示す。例えば、金利の変動（ノード 368）を Z としておいた時に、金融政策（ノード 2179）は、金利の変動（ノード 368）との関連が認められたため、因果連鎖から削除される。もし、「事業再編（ノード 1402）が必ずレイオフ（ノード 2000）につながるか否か」という因果関係を特定する場合、金利の変動（ノード 368）が有効な操作変数として機能する可能性が高いことがここから分かる。

操作変数の評価に関して、ETE-FinCa から抽出された操作変数を、以下のスコアリング条件に基づき、「高品質（*3* 点）」、「中品質（*1* ～ *2* 点）」、「低品質（*0* 点）」の 3 段階に分類した。評価指標は以下の通りである。

図表3　DFS アルゴリズムにおける因果変数識別の一例

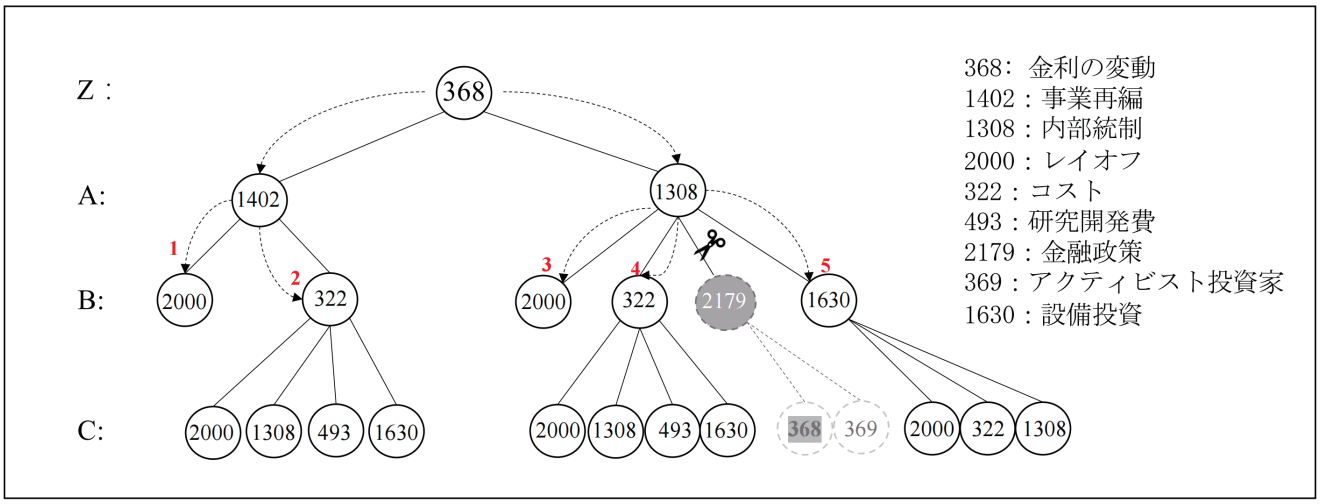

出所）Chen et al.（2024）中の図を許諾を得て改変。

図表4　操作変数の品質およびエッジノードに関する結果

データセット	因果連鎖パターンの数			
	操作変数はエッジノード	低品質	中品質	高品質
全 FinCaKG	446	9,973	9,618	87
SH-FinCaKG	294	3,260	5,577	95
ST-FinCaKG	345	7,811	5,701	21

出所）Chen et al.(2024)中の図を許諾を得て改変。

- 変数 Z が、グラフの端のノード（edge node）である場合（＋ 1 点）
- Z と A の間の重み $w_{z,a}$ が 5.0 以上である場合（＋ 1 点）
- A と B の間の重み $w_{a,b}$ が 5.0 以上である場合（＋ 1 点）

図表 4 は、FinCaKG およびそのサブグラフにおける「操作変数―処置―結果変数」型の因果関係について、低品質、中品質、高品質に分類した件数を示している。SH-FinCaKG は、95 件という多くの高品質の操作変数と、それに対応する説明可能な因果関係を一意に識別している。しかし、ST-FinCaKG では、高品質操作変数を用いると、実際に識別可能な因果関係は 21 件にとどまる。一方で、ST-FinCaKG は、345 個のエッジノードが含まれており、より多くの専門知識を含んでいるが、高品質の因果関係は少ないため、その多くの因果関係は交絡している可能性があると言える。SH-FinCaKG は、ST-FinCaKG と比較して、より多くの高品質な因果連鎖を抽出できているため、「株主価値の最大化」という視点に対して、より明確で説得力のある説明を提供していると言える。この違いが生まれた原因として、ST-FinCaKG の方が、より多くのエッジノード（345 個）を含んでいるにもかかわらず、SH-FinCaKG と比べて変数間の結び付きが弱い（重みが小さい）ことが考えられる。これにより、SH-FinCaKG における専門知識は、より明確に「視点（standpoint）」を表している可能性があると言える。

また、異なるサブグラフから識別された操作変数のパターンの比較も行った。図表 5 に示すように、ST-FinCaKG に固有の操作変数は 870 個、SH-FinCaKG に固有の操作変数は 546 個、両方に共通して含まれる操作変数は 1020 個であった。この結果は、FinCaKG における専門知識の大部分が、この分野に共通するものであることを示唆している。ここで重要な問いが生ずる。特定のサブグラフでのみ観測される因果関係は、専門家の視点バイアスに起因するのか、それとも特定の企業タイプに固有の論理的パターンを反映しているのか。この問題については、次節において実際の経済データを用いてさらに検討する。

図表5　株主指向とステークホルダー指向の重なりを示すベン図

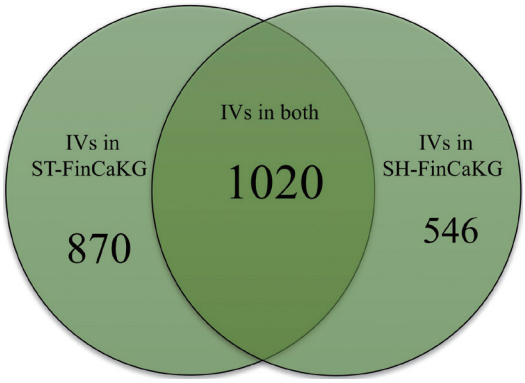

図表6　視点に基づく因果関係選択の実証分析結果

連鎖	ノード選択	二段階最小二乗法（ステージ）	二段階最小二乗法回帰係数	t 値	統計量（Anderson/CD Wald F）
ST-FinCaKG	Z：経済的エクスポージャー A：EBITDA B：コーポレートガバナンス	第 1 段階：Z → A 第 2 段階：A → B	-0.645*** 26.100***	-4.92 3.84	24.96***/12.49
SH-FinCaKG	Z：原油価格 A：営業利益 B：短期有価証券	第 1 段階：Z → A 第 2 段階：A → B	-1.102*** 0.340***	-3.06 2.55	11.43***/11.41

注）　*** p<0.01, ** p<0.05, * p<0.1

出所）Chen et al.（2024）中の図を許諾を得て改変。

4.3 実験と結果

ここで、特定のサブグラフにのみ存在する高品質な操作変数を識別し、二段階最小二乗法回帰を実行することで、「処置―結果変数」の方向性効果および統計的有意性を解釈し、最終的に専門知識の一般化を図った。そして、因果関係の妥当性を検証するために、二段階最小二乗法回帰の統計的結果を算出し、因果推論の正当性を評価した。

全体の中で、高品質な操作変数に着目し、ST-FinCaKG における因果関係（経済的エクスポージャー → EBITDA → コーポレートガバナンス）、および SHFinCaKG における因果関係（原油価格 → 営業利益 → 短期有価証券）の 2 つの視点に基づく因果連鎖を検証した。図表 6 は、産業固定効果および年固定効果を考慮した 二段階最小二乗法回帰の結果を示している。ここでは、「経済的エクスポージャー」および「原油価格」を、それぞれ「為替エクスポージャー」および「原油価格エクスポージャー」で代替し、これらは産業ごとの為替および原油価格変動に対する感応度に基づいて算出した。また、「コーポレートガバナンス」の代理変数としては、社外取締役の比率を用いた。

為替エクスポージャーを用いた分析により、EBITDA がコーポレートガバナンスに与える正の効果が明らかとなり、その回帰係数は 26.1（$p<0.01$）であった。通常は、コーポレートガバナンスが良いと EBITDA を高める効果があると考えられるが、ここでは逆の関係となってる。今回は、ステークフォルダー指向の企業に関して見られた因果関係であり、こうした会社は EBITDA が高い時に、ガバナンスを整備するものであり、EBITDA を高めるために、

ガバナンスを強化するという発想が薄いことが示唆される。その一方で、株主指向の企業には、そうした因果関係は確認されていない。また、原油価格エクスポージャーに基づく分析では、営業利益が短期有価証券に与える正の効果が特定され、回帰係数は 0.34（$p<0.01$）であった。Anderson Canon. Statistics は有意（$p<0.01$）であり、また Craig Donald Wald F も 10 を超えていることから、操作変数 Z が関連性の仮定（$Cov(Z,A) \neq 0$ ）、および外生性の仮定（$Cov(Z, \varepsilon_2) = 0$）を満たしていることが示唆される。株主指向の企業では、環境の変化に対する利益の影響が保有する現金の決定係数になっており、現金保有が外部環境の変化に対して企業価値を守るための安全弁になっていると解釈できる。一方、ステークフォルダー指向の企業は、もしものために現金を蓄積する傾向があり、このような因果関係が見られない。これらの結果は、特定の因果関係が、全体においても統計的に有意であることを示しており、サブグラフにおいてのみ観測された因果関係が、現実世界における視点ベースのバイアスを反映している可能性が高いことを意味していると言える。

5．認知バイアスの特定

5.1 自己奉仕的帰属バイアス

経営者の視点の違いは、情報の解釈や対応の仕方に影響を与える認知バイアスに起因している可能性がある。経営者の認知バイアスは、行動ファイナンスの実証研究において注目されてきた。特に、自信過剰な経営者は、自身の意思決定の正確性を過大評価し、確率的事象における不確実性を過小評価する傾向がある。この理論に基づき、実験経済学や社会心理学では、経営者の認知バイアスや過剰な自信が、企業の政策決定、資本構成、投資行動、株価予測などの財務的意思決定に与える影響について、定義・実証分析が行われてきた。先行研究では、経営者の過信の測定は、主に心理実験や、CEO によるストックオプション行使行動などに関連する行動指標を用いた間接的手法によって測定されている（Malmendier and Tate, 2008）。しかし、日本では、一般に株価連動型のストックオプションが行使されることが少なく、この測定手法を日本企業に適用することは困難である。さらに、実証研究では、しばしば事例選択バイアスや事例サイズの不足といった課題がある。自信過剰な経営者は、良好な業績を自身の能力に起因させ、不振の結果を外部要因のせいにする傾向となる自己奉仕的帰属バイアス（Self-serving Attribution Bias）があることが知られている。本稿では、陳他（2024）の研究に基づき、データ・セット CC-BizEnv を用いてモデルの事前学習を行い、その後、財務文書によりファインチューニングを行うことにより、上場企業の経営者が毎年開示するテキストから、認知バイアスを定量化できる可能性があることを示す。

図表7　データセットの構築方法

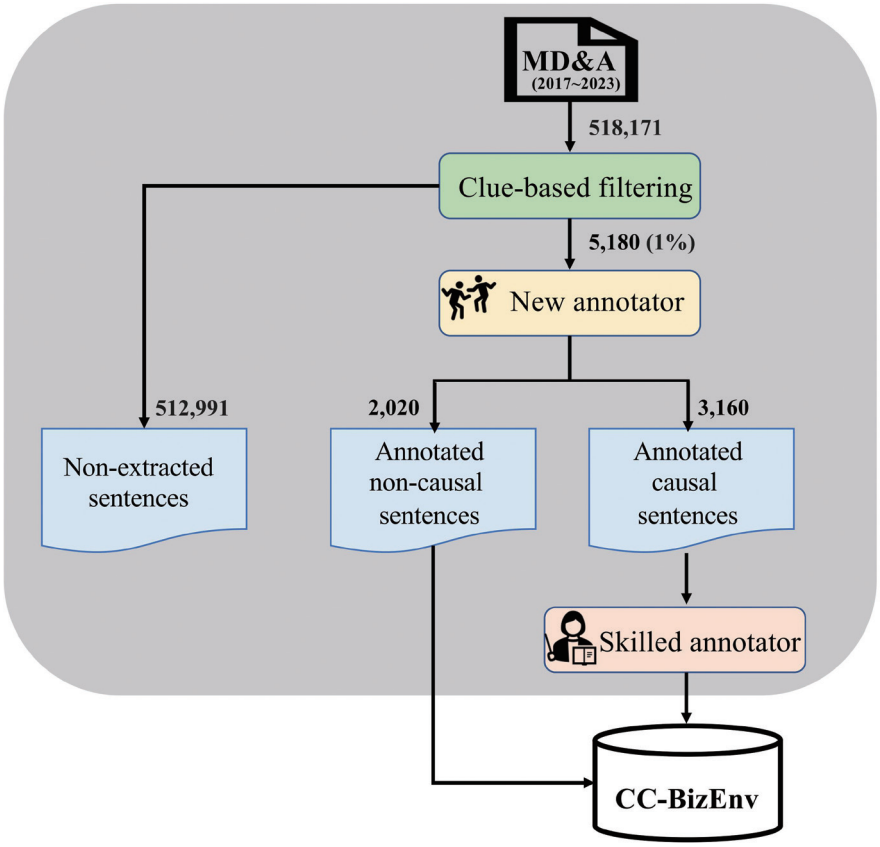

出所）陳他（2024）

5.2 因果関係の抽出と分類

因果関係の抽出を行うために、データ・セット CC-BizEnv を構築した。CC-BizEnv データ・セットの構築（図表 7 参照）に当たり、経済の知識を有する 3 名のアノテータを採用した。そのうち 2 名は、経験のない新規アノテータであり、残りの 1 名は、3 万件以上のアノテーション経験を持つ熟練アノテータである。データ・セットの構築には、企業の年次報告書に含まれる MD&A（経営者による財務状況および経営成績の分析）セクションを用い、300 トークン以上が含まれる 518,171 個の文を抽出した。その中から、因果関係を示唆する文をさらに抽出し、その後、全体の 1% に相当する 5,180 文をランダムに選択した。これらをあらかじめ定義した 4 種類の因果パターン（例：内部要因、外部要因）に分類した。新規アノテータには以下の 2 つのタスクを割り当てた：

1. 文中に因果関係が含まれているかの判定
2. 「手がかり（clue）」、「内部要因」、「外部要因」、「肯定的結果」、「否定的結果」に該当するスパンに対して、タグ付けを行う作業

その後、熟練アノテータが全件をレビューし、必要に応じて修正を加えた。このプロセスにより、最終的に 3,160 文の高品質なラベル付きデータが得ら

れ、CC-BizEnv データセットが構築された。

経営者の因果的推論を抽出するために、LSTM、Bi-LSTM-CRF、ELECTRA、BERT を含む複数のモデルを比較した。評価指標は、スパンとの部分一致に基づき、適合率、再現率、F1 スコアを用いた。アノテータの専門性の違いを調べたところ、熟練アノテータによってアノテーションを精緻化した場合、学習結果が有意に改善されていた。同一の高品質データセットを用いた場合、BERT は他のモデルを上回る性能を示し、F1 スコアで 87.4% を達成した。これは、ELECTRA(53.4%)、LSTM(63.5%)、Bi-LSTM-CRF(67.8%)と比較すると顕著な差がある。他のモデルは、「肯定的結果」および「否定的結果」の識別において、一定の効果しか示さなかった。最後に、より高度な大規模言語モデル (LLM) を用いたゼロショット評価も実施した。CC-BizEnv データセットでファインチューニングされた BERT モデルは、ゼロショット設定下の Claude-3.5-Sonnet（67.9%)、GPT-3.5-Turbo（27.3%)、GPT-4o-2024-05-13（31.7%）を大きく上回り、全体で最高の性能（87.4%）を示した。

5.3 自信過剰の測定と経済的影響

ここでは、経営者が肯定的な成果を内部要因（例：経営能力）に、否定的な成果を外部要因（例：COVID-19 など）に帰属させる文を抽出する手法を説明する。

SAB 指標（Self-serving Attribution Bias Index）は、年次報告書内のすべての因果的帰属文のうち、自己奉仕的な帰属文の割合を測定するものであり、経営者の帰属バイアスを定量的に評価する指標である。これまでの実証研究（Chen et al., 2025）によれば、SAB 指標が高い企業は、誤った予測や過度の楽観主義といった既存の経営者過信指標と有意に相関していることが示されている。一方で、SAB 指標は、CEO の年齢、在任期間、および理工系学歴とは負の相関を示している。経済的観点から見ると、SAB 指標が高い企業は、配当支払いの減少、自社株買いの増加、高い財務レバレッジ、価値を毀損する M&A の実施頻度の増加といった、株主価値に対して負の影響を及ぼす行動をとる傾向がある。以上の知見は、SAB 指標が経営者の認知バイアスを評価し、それが企業の財務政策やパフォーマンスに与える潜在的影響を把握する上で、有用なツールとなることを示唆している。

6. おわりに

本稿では、テキストから因果関係を抽出、利用することで、経済的因果関係研究における長年の課題である「可視化問題」に取り組めることを実証した。テキストから因果知識グラフを構築するフレームワーク FinCaKG を活用することで、経済専門家の繊細な視点を取り込んだ因果知識グラフを構築することができる。そして、提案したデータマイニングアルゴリズム ETE-FinCa は、高品質な因果連鎖を効率的に抽出できることを示しており、実際の市場

データを用いた実証分析において、これらの因果連鎖の統計的有意性と頑健性が、厳密な計量経済分析によって確認された。これらの成果は、視点に基づく因果知識グラフが、因果推論の精緻化、より正確な経済モデリングの支援、政策分析の高度化に貢献し得ることを示唆している。すなわち、経済現象を構造的かつ解釈可能、かつデータ駆動型に表現する有力な手段として、本アプローチの有用性が示されたと言える。また、自信過剰といった経営者の視点の違いを、効果的に捉える CC-BizEnv データセットと合わせると、主観的な視点が経済的ナラティブや、意思決定にどのような影響を及ぼすのかを、包括的に理解するための道を切り拓くことができるであろう。因果テキスト分析と定量的モデリングを統合することで、企業コミュニケーションにおける行動的側面の検証に新たな視点を提供することができ、このような手法を利用することで、経済領域における因果ダイナミクスの解釈可能性を一層深化させることができる。

今後の展望として、因果知識グラフは、ニュース記事、ソーシャルメディア、専門家による解説といった追加的なデータソースを取り込むことで、より多様かつきめ細かな視点の抽出へと発展させることができる。さらに、高度な生成型大規模言語モデル技術や因果発見アルゴリズムとの統合により、因果関係抽出の精度およびスケーラビリティの向上が期待される。テキスト分析と因果推論を組みあわせることで、より透明性が高く、説明可能な AI システムの基盤技術として、ステークホルダーが的確な意思決定を行うために広く利用されていくことが期待される。

参考文献

Ali, W., Zuo, W., Ali, R., Zuo, X., and Rahman, G. (2021). Causality mining in natural languages using machine and deep learning techniques: A survey. *Applied Sciences,* 11:10064.

Bennett, B. (2011). Possible worlds and possible meanings: A semantics for the interpretation of vague languages. In *Proceedings of AAAI Spring Symposium: Logical Formalizations of Commonsense Reasoning*, pp. 23-29.

Chang, D.-S. and Choi, K.-S. (2004). Causal relation extraction using cue phrase and lexical pair probabilities. In *Proceedings of International Conference on Natural Language Processing,* pp. 61-70. Springer.

Chen, Y., Kimura, Y., and Inoue, K. (2025). Measuring self-serving attribution bias using text mining. *Available at SSRN 5130571*.

Chen, Y., Xu, Z., Inoue, K., and Ichise, R. (2024). Causal inference in finance: An expertise-driven model for instrument variables identification and interpretation. In *Proceedings of the 23rd International Conference on Machine Learning and Applications,* pp. 1089-1094.

Conneau, A., Khandelwal, K., Goyal, N., Chaudhary, V., Wenzek, G., Guzmán, F., Grave, É., Ott, M., Zettlemoyer, L., and Stoyanov, V. (2020). Unsupervised cross-lingual representation learning at scale. In *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics*, pp. 8440-8451.

De Cao, N., Izacard, G., Riedel, S., and Petroni, F. (2021). Autoregressive entity

retrieval. *In Proceedings of the 9th International Conference on Learning Representations*.

De Cao, N., Wu, L., Popat, K., Artetxe, M., Goyal, N., Plekhanov, M., Zettle-moyer, L., Cancedda, N., Riedel, S., and Petroni, F. (2022). Multilingual autoregressive entity linking. *Transactions of the Association for Computational Linguistics,* 10:274-290.

Devlin, J., Chang, M.- W., Lee, K., and Toutanova, K. (2019). BERT: Pretraining of deep bidirectional transformers for language understanding. In *Proceedings of the Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies,* pp. 4171-4186.

Elman, J. L. (1990). Finding structure in time. *Cognitive science,* 14(2):179-211.

Frattini, J., Fischbach, J., Mendez, D., Unterkalmsteiner, M., Vogelsang, A., and Wnuk, K. (2023). Causality in requirements artifacts: prevalence, detection, and impact. *Requirements Engineering*, 28:49-74.

Girju, R. (2003). Automatic detection of causal relations for question answering. In *Proceedings of the ACL workshop on Multilingual summarization and question answering,* pp. 76-83.

Heindorf, S., Scholten, Y., Wachsmuth, H., Ngonga Ngomo, A.- C., and Potthast, M. (2020). Causenet: Towards a causality graph extracted from the web. In *Proceedings of the 29th ACM International Conference on Information & Knowledge Management,* pp. 3023-3030.

Huguet Cabot, P.- L. and Navigli, R. (2021). REBEL: Relation extraction by end-to-end language generation. In *Findings of the Association for Computational Linguistics: EMNLP 2021,* pp. 2370-2381.

Lample, G., Ballesteros, M., Subramanian, S., Kawakami, K., and Dyer, C. (2016). Neural architectures for named entity recognition. In *Proceedings of the Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies,* pp. 260-270.

Lane, N. (2020). The new empirics of industrial policy. *Journal of Industry, Competition and Trade,* 20(2):209-234.

LeCun, Y., Bottou, L., Bengio, Y., and Haffner, P. (1998). *Gradient-based learning applied to document recognition. Proceedings of the IEEE,* 86(11):2278-2324.

Li, Z., Ding, X., Liu, T., Hu, J. E., and Van Durme, B. (2020). Guided generation of cause and effect. In *Proceedings of the 29th International Joint Conference on Artificial Intelligence,* pp. 3629-3636.

Lu, Y., Liu, Q., Dai, D., Xiao, X., Lin, H., Han, X., Sun, L., and Wu, H. (2022). Unified structure generation for universal information extraction. In *Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics,* pp. 5755-5772.

Luo, Z., Sha, Y., Zhu, K., Hwang, S.- W., and Wang, Z. (2016). Commonsense causal reasoning between short texts. In *Proceedings of the 15th International Conference on Principles of Knowledge Representation and Reasoning,* pp. 421-430.

Malmendier, U. and Tate, G. (2008). Who makes acquisitions? ceo overconfidence and the market's reaction. *Journal of financial Economics,* 89(1):20-43.

O'Brien, S. P. (2010). Crisis early warning and decision support: Contemporary approaches and thoughts on future research. *International Studies Review,* 12(1):87-104.

Orlando, R., Huguet Cabot, P.- L., Barba, E., and Navigli, R. (2024). ReLiK: Retrieve and LinK, fast and accurate entity linking and relation extraction on an academic

budget. In *Findings of the Association for Computational Linguistics ACL 2024,* pp. 14114-14132.

Pearl, J. (2010). On a class of bias-amplifying variables that endanger effect estimates. *In Proceedings of the 26th Conference on Uncertainty in Artificial Intelligence,* pp. 417-424.

Radinsky, K., Davidovich, S., and Markovitch, S. (2012). Learning causality for news events prediction. In *Proceedings of the 21st International Conference on World Wide Web,* pp. 909-918.

Rink, B., Bejan, C. A., and Harabagiu, S. (2010). Learning textual graph patterns to detect causal event relations. In *Proceedings of the 23rd International Florida Artificial Intelligence Research Society Conference*.

Rosenbaum, P. R. and Rubin, D. B. (1983). The central role of the propensity score in observational studies for causal effects. *Biometrika*, 70:41-55.

Rossiello, G., Chowdhury, M. F. M., Mihindukulasooriya, N., Cornec, O., and Gliozzo, A. M. (2023). Knowgl: knowledge generation and linking from text. In *Proceedings of the 37th AAAI Conference on Artificial Intelligence*, pp. 16476-16478.

Sorgente, A., Vettigli, G., and Mele, F. (2013). Automatic extraction of causeeffect relations in natural language text. In *Proceedings of the 7th International Workshop on Information Filtering and Retrieval, co-located with the 13th International Conference of the Italian Association for Artificial Intelligence,* volume 1109, pp. 37-48.

Spirtes, P., Glymour, C., and Scheines, R. (2000). *Causation, Prediction, and Search*. 2nd edition.

Straková, J., Straka, M., and Hajic, J. (2019). Neural architectures for nested NER through linearization. In *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics,* pp. 5326-5331.

Tang, W., Xu, B., Zhao, Y., Mao, Z., Liu, Y., Liao, Y., and Xie, H. (2022). UniRel: Unified representation and interaction for joint relational triple extraction. In *Proceedings of the Conference on Empirical Methods in Natural Language Processing,* pp. 7087-7099.

Vrandecic, D. and Krötzsch, M. (2014). Wikidata: A free collaborative knowledgebase. *Communications of the ACM,* 57(10):78-85.

Wang, C., Liu, X., Chen, Z., Hong, H., Tang, J., and Song, D. (2022). DeepStruct: Pretraining of language models for structure prediction. In *Findings of the Association for Computational Linguistics: ACL 2022,* pp. 803-823.

Xu, Z., Nararatwong, R., Kertkeidkachorn, N., and Ichise, R. (2022). iLab at FinCausal 2022: Enhancing causality detection with an external cause-effect knowledge graph. In *Proceedings of the 4th Financial Narrative Processing Workshop,* pp. 124-127.

Xu, Z., Takamura, H., and Ichise, R. (2025). Fincakg: A framework to construct financial causality knowledge graph from text. *International Journal of Semantic Computing*, 19:02, pp. 321-340.

Ye, H., Zhang, N., Chen, H., and Chen, H. (2022). Generative knowledge graph construction: A review. In *Proceedings of the Conference on Empirical Methods in Natural Language Processing,* pp. 1-17.

Yin, W., Kann, K., Yu, M., and Schütze, H. (2017). Comparative study of cnn and rnn for natural language processing. *arXiv preprint ar Xiv:1702.01923*.

陳穎・井上光太郎・市瀬龍太郎.（2024）. 有価証券報告書からの経営者による経営環境と企業業績に関する因果認知の抽出. 人工知能学会第二種研究会資料, Fin-033:163-168.