

# グラフニューラルネットワークを用いた レビューデータの因果関係に基づく評価構造可視化

東 剛且<sup>†</sup> 橋本 翔<sup>†‡</sup> 杉本 匡史<sup>†††</sup> 長田 典子<sup>†</sup>

<sup>†</sup>関西学院大学理工学部/感性価値創造インスティテュート 〒669-1330 兵庫県三田市学園上ヶ原 1 番

<sup>†‡</sup>西南学院大学商学部 〒814-8511 福岡市早良区西新 6-2-92

<sup>†††</sup>阪南大学国際学部 〒580-8502 大阪府松原市天美東 5-4-33

E-mail: <sup>†</sup>{takeruazm424-gt, nagata}@kwansei.co.jp <sup>†‡</sup>s-hashimoto@seinan-gu.ac.jp <sup>†††</sup>sugimoto@hannan-u.ac.jp

あらまし 本研究ではグラフニューラルネットワークベースのモデルを用いてレビューデータから評価構造を可視化する手法を提案する。提案手法では、評価構造を有向非巡回グラフと捉え、グラフニューラルネットワークによる推論を行う。まず、学習データに感性の階層性を考慮した因果ペアデータを導入し、言語特徴をエッジ特徴量に含め Edge Graph Attention Networks ベースのモデルで学習を行う。次に最大スパンニング木とトポロジカルソートを考慮したグラフ構築手法により概念の方向性を考慮したグラフ構造を構築する。実験の結果、特に言語特徴が精度に大きく寄与していることを示し、本手法の有用性を示唆した。

キーワード 評価構造, 因果推論, グラフニューラルネットワーク, 有向非巡回グラフ

## Causality-based evaluation structures visualization of review data using Graph Neural Networks

Takeru AZUMA<sup>†</sup> Sho HASHIMOTO<sup>†‡</sup> Masashi SUGIMOTO<sup>†††</sup> and Noriko NAGATA<sup>†</sup>

<sup>†</sup>School of Science and Technology / Kwansei Gakuin Institute of Kansei Value Creation, Kwansei Gakuin University  
1 Uegahara, Gakuen, Sanda-shi, Hyogo, 669-1330 Japan

<sup>†‡</sup>Faculty of Commerce, Seinan Gakuin University, Nishiara, Hukuoka-shi, Hukuoka, 814-8511 Japan

<sup>†††</sup>Hannan University, Amamihigashi, Matsubarashi, Osaka, 580-0032 Japan

E-mail: <sup>†</sup>{takeruazm424-gt, nagata}@kwansei.co.jp <sup>†‡</sup>s-hashimoto@seinan-gu.ac.jp <sup>†††</sup>sugimoto@hannan-u.ac.jp

**Abstract** We propose a method to visualize evaluation structures from review data using a graph neural network-based model. The proposed method considers the evaluation structure as a directed acyclic graph and performs inference using a graph neural network. First, we introduce causal pair data considering the hierarchy of sensitivities into the training data and include linguistic features in the edge features and train with an Edge Graph Attention Networks-based model. Next, we construct a graph structure that considers the directionality of concepts by using a graph construction method that takes into account maximum spanning trees and topological sorting. Experimental results show that linguistic features contribute significantly to accuracy, suggesting the usefulness of this method.

**Keywords** Evaluation Structure, Causal Inference, Graph Neural Networks, Directed Acyclic Graphs

### 1. はじめに

プロダクトデザインにおいて、ユーザーニーズを的確に把握することの重要性が高まっている。近年、ユーザーニーズは機能や価格といった実用的価値だけでなく、使用感や快適性などの感性的価値も注目されている。このような感性的価値を扱うアプローチとして感性工学が重要な役割を果たしている。感性工学では従来、このユーザーニーズを把握する手法としてインタビュー調査や主観評価実験による心理学的データの収集と分析によって行われてきた。特に代表的なインタビュー手法として評価グリッド法がある。評価グリッド法で

は、抽象的な価値判断・心理的な価値から客観的な判断・物理的な状態までを階層的に整理し評価構造として視覚化する。このような構造を用いることで、特定の印象や感情がどのように生じるのかを予測することが可能となり、個人差の検討が容易になるという利点がある。また、評価構造は評価グリッド法のラダリングと呼ばれる手法により、評価項目間の上位概念と下位概念の因果関係を考慮した構造を構築する。この因果関係を適切に捉えることで、感性的な価値の構造をより深く理解し、個人差を伴うユーザーの価値構造を解明できる。しかし評価グリッド法はその有用性から多

くの研究で用いられているものの、人的・時間的負荷が高いという課題があり大量データの収集・分析に課題が残る。

評価構造図で可視化される構造は、感性の階層構造である「感情・価値—印象—物理量」[1]と同値とみなせる。この階層モデルは、評価対象の物理特性から心理的な反応を介し総合的な評価が形成されるため、各層の因果関係を有向非巡回グラフ (DAG) で表現できる。従来の感情分析タスクでは、単語間の関係性や共起関係に着目した感情極性を推論するタスクが主流で、因果関係を正確に捉えるまでの応用には至っていない。しかしグラフニューラルネットワーク (GNN) の発展により、ノード間の非線形な因果関係をモデル化することが可能となっている。そのため、GNN モデルにより単語間や文脈間の因果関係を捉え、文章内の意味的つながりを考慮し感情分析に大きく貢献している。そこで本研究では、評価構造の可視化を DAG の構築タスクととらえ、GNN ベースのアプローチにより効率的に評価構造を可視化する手法を提案する。また、評価構造を効率的に可視化する手法において、感性評価における因果関係を直接活用するため、因果ペアという概念を用いる。因果ペアを導入することで、効率的に評価構造を学習することが可能となり、評価構造の解釈が容易になる。さらに、言語特徴量を考慮したグラフニューラルネットワークモデルを構築することで、因果ペアの情報を最大限活用し、従来のテキストデータからの因果推論手法の課題を克服する。

## 2. 関連研究

### 2.1. 評価グリッド法

評価グリッド法はパーソナル・コンストラクト理論と呼ばれる「人間は経験を通じて固有の認知構造を作り上げ、その認知構造によって環境及び行動を理解し、その結果を予測する」という理論を背景とし改良された面接手法を利用し、人の認知構造に基づいた評価構造を抽出する手法である[2]。このインタビュー手法の手順は次のとおりである。インタビュアーは、まず評価対象となる複数の刺激を用意し、被験者に嗜好順に並べてもらう。次に、被験者になぜそのような順を判断したか理由を尋ねる。そこで得られた評価項目に対し、ラダリングという手法を用いて評価項目に対する上位概念・下位概念を引き出す。評価グリッド法は、半構造化されており手順が決められているが、1回のインタビューに多くの時間を要し、より多くのデータが必要な場合時間的負担も増大するため、大規模なデータを取ることは困難である。

大谷らはこの評価グリッド法の課題を解決するために、レビューデータから係り受け解析に基づく評価構造の構築を行った[3]。レビューデータから複数の辞

書を用いて抽出した評価語を感情語と印象語に分類し、収集した印象語の係り受け関係を調べその関係をエッジとするネットワーク構造を作成した。しかしこの手法では各項目が単語のみ格納されているため、評価構造の解釈の難しさや因果関係を正しく処理できないという課題がある。

### 2.2. グラフベースアプローチを活用したセンチメント分析

グラフベースアプローチを活用したセンチメント分析では様々な手法が試みられている。アスペクトベースのトリプレットセンチメント分析である ASTE タスクにおいては、複数の言語特徴を活用するためにマルチチャンネルの Graph Convolution Network (GCN) を実装した EMC-GCN を提案している[4]。この手法により、単語間の関係や言語特徴というテキストの詳細情報を最大限に活用したうえでベースライン手法を上回る制度を達成しているが、本研究の目的である直接的な構造化には至っていない。また、センチメント分析において文間の構造情報を適切に表現できないという問題を解決するため、Caoらは Graph Attention Networks と融合した感情—原因ペアの因果関係検出法を提案している[5]。単語レベル、文レベルの学習により節間の局所的・大域的な依存関係情報を取得し、文書内の異なる文間の構文依存情報を統合した。しかし本研究のような多層的な評価構造を扱えないため、評価構造を可視化するには不十分である。

### 2.3. テキストデータの因果推論・構造化

自然言語処理の分野では、イベント間の因果推論、情報整理のための構造化に関する研究が多くされている。文章の構造的言語処理に基づきイベントの原因・理由・解決策をもとに因果関係グラフを構築する手法[6]や、論文の引用・被引用関係をもとに論文引用ネットワークを構築し、特定の技術的トピックに関する研究[7]が行われている。これらの研究は、主に文書の情報整理手法に限定されており、個人差を解明できる評価構造の抽出手法においては依然として困難である。

## 3. 提案手法

本研究の目的は、従来の評価構造の可視化手法の課題を克服するため、グラフニューラルネットワークベースのモデルを用いてレビューデータから評価構造を可視化する手法を提案する。提案手法では、評価構造を有向非巡回グラフと捉え、グラフニューラルネットワークベースモデルによる推論を行う。まず、学習データに感性の階層性を考慮した因果ペアデータを導入し、言語特徴をエッジ特徴量に含め Edge Graph Attention Networks ベースのモデルで学習を行う。次に最大スパニング木とトポロジカルソートを考慮したグラフ構築手法により概念の方向性を考慮したグラフ構

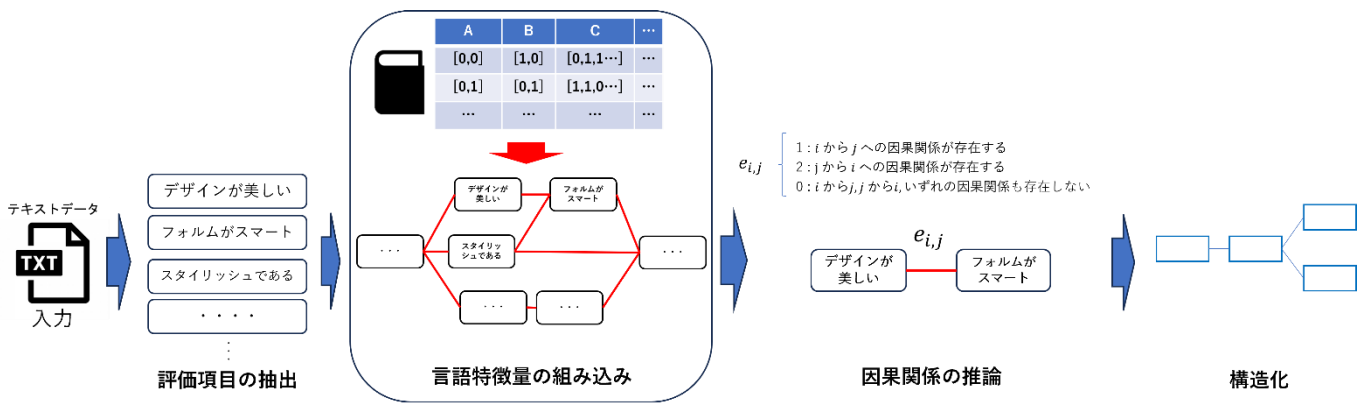


図 2. 提案手法の概念図

造を構築する。

### 3.1. 評価構造と因果ペアの定義

評価構造は、評価グリッド法のラダリング手法により評価項目の上位概念・下位概念を抽出する。抽出された因果関係に基づき構築した評価構造図は感性の階層構造と同義とみなせる。この階層性を感情と印象、印象と形態要素など階層構造の各層同士で因果関係を持つペアが存在する。このペアを本研究では因果ペアと定義する。この因果ペアの集合から評価構造を構築することができ、構築された評価構造は有効非巡回グラフ (DAG) グラフで表現可能である。本研究では、この感性の階層性を考慮した DAG グラフを、因果ペアの学習から推論することを目的とする。さらに、因果ペアにおける感性の階層性などの情報を最大限活用するために、各ペアの言語特徴をエッジに組み込む。この目的を達成する提案手法の概念図を図 2 に示す。

### 3.2. 文脈的特徴を用いた評価項目と因果ペアの抽出

本研究で利用するデータは、学習データがインタビュー手法などにより構築した因果ペア情報を持つ評価構造データ、推論対象データがレビューデータである。レビューデータにおいては、文脈的特徴を用いて評価項目と因果関係の抽出を行う。

#### 3.2.1. 文脈的特徴を踏まえた評価項目の抽出

テキストデータから構造を推論するために、評価項目の抽出を行う。まず、与えられた文章を正規化し、評価項目を抽出しノードを構築する。ここで、評価項目抽出には主に 2 つの要素を用いる。1 つ目は談話関係における談話単位である。これは意味的つながりを解析する談話関係解析において、節という意味のまとまりごとに分割されている構成単位を利用する。2 つ目の要素は外の関係である。これは修飾節と主名詞の間に格関係をもたない特徴を利用する。これらの 2 つの要素を用いることで、評価項目の解釈性を高めつつ、より詳細な視点からの評価項目抽出を可能にする。

### 3.2.2. 感性の階層性を考慮した言語特徴の抽出

因果ペアに感性の階層性を考慮するため、因果ペアを構成する両ノードから言語特徴を抽出し、エッジ特徴量として組み込む。抽出する特徴を表 1 に示す。これらの特徴を抽出し、明示的に感性の階層性を考慮したモデルを構築し、より精度の高い評価構造を構築する。なおこれらの特徴量は日本語アプレイザル評価表現辞書[8]と感情表現辞典の 2 種類を用いる。

表 1. 抽出する言語特徴の詳細

言語特徴の種類	データの内容
評価表現の有無	1: 評価表現, 0: 評価表現でない
評価表現のカテゴリ	全 17 カテゴリ (情動・心状・価値など)
評価表現のカテゴリをさらに細分化したものを	上記 17 カテゴリをさらに細分化した全 227 特徴 (嬉しさ・快感・感動・巧妙など)
日本語評価極性辞書 (用言編) にマッチする語が含まれているかを示す	1: 含む, 0: 含まない
日本語評価極性辞書 (用言編) に含まれる語の感情極性	1: ポジティブ, 2: ネガティブ, 3: ニュートラル, 0: 日本語極性辞書 (用言編) に含まれていない

### 3.3. 構造学習

本手法で構築する評価構造は、感性の階層性を考慮した有向非巡回グラフである。そのために、因果ペアを用いたグラフベースのモデルで学習する。因果ペアのエッジ特徴量として組み込んだ情報を最大限活用するため、エッジ特徴量を学習可能な Edge-Featured Graph Attention Networks (EGAT) [9]を利用する。EGAT はノードと特徴量とエッジ特徴量の両方を入力とし並列且つ相互に学習を行うことで、双方の特徴量を効率的に学習する。また、2 層の EGAT を通した後最終出力の直前に Attention スコアを算出し、因果ペアを構成する両ノード情報とエッジ情報を再度結合して重みづけを行う Attention Layer を導入する。これにより、上位ノード・下位ノード間の影響関係を表すことができ、評価構造内に特に重要な因果関係をモデル化することができる。出力は head, tail におけるエッジの存在確率で、エッジあり、エッジなし、逆向きのエッジありの

表 3. 学習データのドメインごとの結果

Metrics	All	Comfort	Sound	Tourism	Interior	Driving1	Driving2	Risk	Film	Image	Appearance	Tactile
TPR(Label0)	0.227	0.122	0.357	0.491	0.495	0.688	0.277	0.294	0.320	0.573	0.141	0.134
TPR(Label1)	0.712	0.921	0.567	0.472	0.572	0.446	0.599	0.500	0.598	0.469	0.710	0.658
TPR(Label2)	0.726	0.958	0.534	0.476	0.582	0.446	0.659	0.583	0.578	0.506	0.681	0.610
FPR(Label0)	0.135	0.013	0.225	0.328	0.243	0.212	0.243	0.213	0.268	0.308	0.106	0.126
FPR(Label1)	0.160	0.029	0.260	0.226	0.208	0.254	0.173	0.239	0.208	0.184	0.244	0.304
FPR(Label2)	0.172	0.072	0.262	0.215	0.216	0.250	0.214	0.291	0.194	0.234	0.216	0.227
SHD	3.834	0.171	9.662	15.566	11.097	13.438	5.267	5.346	14.529	9.493	1.605	1.931
GED	3.671	0.080	9.184	16.640	11.546	16.340	4.620	4.300	14.529	8.642	1.101	1.341

3 値で表現する。

### 3.4. 評価構造の構築

学習済みモデルの出力である因果ペアごとのエッジの存在確率を用いて評価構造を構築する。本研究では 2 種類の方法で構築する；3 値の中で最大確率を算出しエッジを決定する方法と、Rashid らの手法に則った最大スパニング木とトポロジカルソートを考慮したグラフ構築手法である [10]。Rashid らの手法は、エッジの存在確率を用いて全ノードを包含する最大スパニング木と、ノードの順序を考慮しエッジの方向を決定するトポロジカルソートを考慮したグラフ構築手法である。この手法により、すべてのノードが必ず 1 つ以上のエッジを持つグラフを構成することができるため、レビューデータの情報を最大限活用可能である。また、トポロジカルソートによりノードの順序を考慮した因果関係を定式化するため、上位概念・下位概念の方向性を考慮したグラフ構築が可能となる。

## 4. 性能評価実験

本手法の性能評価を検証するため、本研究では 2 種類の実験を行う。1 つ目は学習データを利用した構造学習効果の検証、2 つ目は実データを利用した評価構造の推論精度検証である。

本モデルの評価において、テキストエンコーダとして Sentence-BERT [11] である `sonois/sentence-bert-base-ja-mean-tokens-v2` を使用する。モデルの入力はノードが 768 次元、エッジ特徴量が 42 次元である。EGAT モデルは AdamW optimizer を使用し学習率を 0.001、weight decay を  $1e-3$ 、ドロップアウトを 0.01 に設定し、EGAT モデルの隠れ層はノード特徴を 256、エッジ特徴を 128 に設定する。

検証対象手法は次の 3 つである；①最大スパニング木とトポロジカルソートを考慮したグラフ構築手法（本手法）②エッジの存在確率の最大のものでエッジを決定する方法（Prob-base）③エッジ特徴量を含めず Graph Attention Networks で学習した推論モデル手法（GAT）である。

### 4.1. データセット

利用するデータは手作業で構築した評価構造データ全構造数 3,968、全ノードペア数 8,712 である。本データは次の 11 ドメインで構築した合成データである；快適性 (Comfort)、音 (Sound)、観光 (Tourism)、インテリア (Interior)、運転 (Driving1, Driving2)、リスク (Risk)、フィルム (Film)、イメージ (Image)、外観 (Appearance)、触感 (Tactile)。これらのデータに加えて、各因果ペアの因果関係を逆にしたもの、因果関係のない因果ペアを作成し、学習データに含める。学習データ拡張後の全ノードペア数は 34,969 である。

### 4.2. 構造学習効果の検証

本研究における因果ペアを用いたモデルの学習効果を検証するにあたり、本手法の構造学習の効果検証を行う。学習データにて交差検証を行い、評価構造の再現度を評価する。出力した因果ペアの属性と正解データとの一致率を、4 種類の評価指標を用いて算出する。

#### 4.2.1. 評価指標

出力した評価構造を評価するために、4 つの評価指標を検討する；真陽性率 (TPR)、偽陽性率 (FPR)、構造ハミング距離 (SHD)、グラフ編集距離 (GED) である。EPR, SHD, GED が低いほど性能が良いことを示し、TPR が高いほど性能が良いことを示す。

#### 4.2.2. 結果

5Fold の交差検証の結果を表 2 に示す。実験の結果、本手法は因果関係あり、逆向きの因果関係ありともに TPR が 70% を超え、FPR が約 15% となった。順方向・逆方向に限らず因果関係ありの判定においては一定の性能を示した。しかし因果関係なしの TPR については 25% を下回り、因果関係がないノードペアに対し因果関係が存在するという判定してしまう結果が得られた。

また、ドメイン別の評価結果を表 3 に示す。実験の結果、データセットのドメインにより性能にかなり差があることが示された。

表 2. 構造学習の結果

	本手法	Prob-base	GAT
TPR_(L0)	0.227	0.227	0.000
TPR_(L1)	0.712	0.733	0.478
TPR_(L2)	0.726	0.719	0.478
FPR_(L0)	0.135	0.145	0.010
FPR_(L1)	0.160	0.162	0.509
FPR_(L2)	0.172	0.147	0.509
SHD	3.834	3.427	5.744
GED	3.671	3.638	3.827

### 4.3. レビューデータを用いた性能評価検証

実データであるレビューデータの検証においては、対象プロダクトドメインを自動車とした。構成要素が多くデザインや機能面など多角的な視点で評価される車において、本研究の評価を行うのに適している。利用データは、価格.com の車の評価レビューを用いる。このレビューデータは、2019年6月24日までに書かれたもので、全100レビューデータの評価構造推論結果について評価を行う。因果関係評価対象の因果ペアは、談話関係にあるもの、外の関係にあるもの、その他のノードペアから類似度が高いものから順に選択したものである。評価対象の因果ペアは全3,562ペアである。また、検証対象手法は本手法と確率ベースのグラフ構造化手法 (Prob-base) の2つである。

#### 4.3.1. 評価指標

レビューデータを入力とし、出力した評価構造に対し各因果ペア (i, j) が次の5つの項目のいずれかに当てはまるかを手動で評価し、構造学習の検証と同様の評価指標を算出する。5つ各項目において0~2のクラスを付与し、それぞれでTPR, FPRを算出する。このクラスを利用しグラフを構築し、1レビューごとにSHD, GEDを算出し、平均したものをTPR, FPRとともに最終評価とする。なお因果ペアの分類項目とそれぞれのクラスを表に示す。

表 3. 因果ペアの分類項目とラベル

分類項目	ラベル
i→j の方向に因果関係を示す	L1
i, j が並列関係を示す	
i, j が同値もしくは同義である	
j→i の方向に因果関係を示す	L2
i, j どちらの方向にも関係が存在しない	L0

#### 4.3.2. 結果

本実験の結果を表に示す。レビューデータによる実

験の結果、本手法におけるエッジなし (L0) のTPRは約89%、順方向・逆方向 (L1, L2) とともにエッジありのTPRはともに約35%を示した。また、確率ベースの結果においてはエッジあり (L1, L2) のTPRがともに25%となった。構造学習の結果と比較し、因果関係なし (L0) の評価結果がかなり高い性能を示した。因果ペアの評価対象を談話関係などの文脈的な意味の流れをなすペアを中心に選定しており、まったく脈絡のない因果ペアを推論対象から省いていることから、このように高い性能を示したと考えられる。SHDとGEDの結果から、確率ベースのグラフ構築手法より本手法におけるグラフ構造の構築の性能が上回った。

表 4. レビューデータでの推論結果

	本手法	Prob-base
TPR_(L0)	0.894	0.875
TPR_(L1)	0.368	0.250
TPR_(L2)	0.353	0.262
FPR_(L0)	0.264	0.513
FPR_(L1)	0.076	0.087
FPR_(L2)	0.094	0.097
SHD	8.078	12.689
GED	5.961	5.854

## 5. 考察

### 5.1. 因果ペアを用いたモデルの学習効果

構造学習の効果検証の結果、エッジ特徴量を含む本手法と確率ベースの手法においては、因果関係あり、逆向きの因果関係の推論精度は70%を超え、因果関係のあるエッジを検出する性能が高いことを示した。エッジ特徴量を含めないGATの結果よりも大幅に性能が高いことが示唆された。3つのエッジ属性におけるFPRにおいては、エッジ特徴量を含む手法どちらも20%以下の性能を示した。SHD, GEDにおいても高い性能を示しており、言語特徴をエッジ特徴量に含めるモデルの構造学習能力が高いことを示す。

本研究では汎用性の高いモデル構築を目的としているため、学習データのドメインを8種類計11分類利用した。学習データそれぞれの精度結果を表3に示す。学習データの分布や学習対象の因果ペア数により学習性能が左右されることを示唆しており、今後データ拡張を行う際の課題である。

### 5.3. 定性評価に基づくレビューデータを用いた検証結果

表4より、エッジなし (L0) のTPRは89%と高い精度を示し、本手法においてエッジの誤推論を抑える

ことを示した。提案手法におけるレビューデータを用いた評価構造の主な可視化結果を図3と図4に示す。図3は「サスが固めなので軽い突き上げ感はあるけど、舗装路を走っている分には十分かな。雨音とロードノイズがもう少し小さいといいですね。」というレビューデータを入力とした評価構造の推論結果である。物理的特性である「サスが固めなので」に対しその上位概念である「軽い突き上げ感はある」、そのさらに上位概念である「舗装路を走っている」「分には十分かな」へと因果関係を正しく抽出することを示している。また、「舗装路を走っている」「分には十分かな」の2つの評価項目においては、「十分である」という評価が「舗装路を走っている」という特定の状況に限定されていることを示唆している。このように、意味の流れに基づき評価項目を分けることが、評価構造の解釈性を向上させることを示唆している。




図3. レビューデータからの推論結果①

一方で、レビュー内の「雨音とロードノイズがもう少し小さい」という評価においては、サスの固さに関する評価と因果関係を示していない。レビューデータでは1つのプロダクトに対し、個人差を含むユーザが持つ複数の視点や評価を含む場合が多数あるため、話題の移り変わりを考慮した評価構造の推論が求められる。図4においては、複数の話題を含むレビューに対する推論結果の例である。「足回り」の評価と「後席の狭さ」の評価が分かれた評価構造となっており、話題の移り変わりを考慮した評価構造の推論が可能となっている。しかし「道でこぼこ発券機かといいたくなるほど」「よく拾う」という評価項目にエッジが繋がっていない、「マイルドな乗り心地」という評価と「車高が低い」の間にエッジが繋がっていること、「乗り降りしにくいのが困る」という評価が欠落しているなど、細かな因果関係の推論精度に課題があり、グラフ構築手法のさらなる検討を進めていく必要がある。




図4. レビューデータからの推論結果②

## 6. まとめ

本研究では、レビューデータを用いた評価構造の構築手法を提案し、2つの実験より有用性を検証した。

構造学習の検証においては、因果関係が存在するラベルの推論に有用性を示し、因果関係なしの推論性能とデータ拡張における課題が示唆された。また、レビューデータによる推論結果では、上位概念・下位概念の因果関係の推論を特定の状況に基づいた関係を抽出可能であることを示唆し、有用性が確認された。今後は、レビューデータに対する構造化のデータセットをもとにした評価や、他ドメインのレビューデータでの性能検証を行う。

## 謝 辞

本研究は JSPS 科研費 JP22H03681 の助成を受けた。

## 文 献

- [1] 片平建史, 武藤和仁, 橋本翔, 飛谷謙介, 長田典子. “SD 法を用いた感性の測定における評価の階層性.” 日本感性工学会論文誌, 17.4: 453-463, 2018.
- [2] 讀井純一郎, 乾正雄, “レパートリー グリッド 発展手法による住環境評価構造の抽出—認知心理学に基づく住環境評価に関する研究 (1)—,” 日本建築学会計画系論文, No. 367, pp. 15-22, 1986.
- [3] 大谷俊太, 橋本翔, 杉本匡史, 長田典子, “単語の係り受け関係に基づく印象評価構造の自動構築,” 第 17 回日本感性工学会春季大会, 2D2-04, 2022.
- [4] H. Chen, Z. Zhai, F. Feng, R. Li, X. Wang “Enhanced multi-channel graph convolutional network for aspect sentiment triplet extraction.” In Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics, Volume 1: Long Papers, pp. 2974-2985, 2022.
- [5] Q. Cao, X. Hao, H. Ren, W. Xu, S. Xu, C.J. Asiedu, “Graph attention network based detection of causality for textual emotion-cause pair”, World Wide Web, 26(4), 1731-1745, 2023.
- [6] 清丸寛一, 植田暢大, 児玉貴志, 田中佑, 岸本裕大, 田中リベカ, 黒橋禎夫. “因果関係グラフ: 構造的言語処理に基づくイベントの原因・結果・解決策の集約”, 言語処理学会 第 26\*回年次大会, \*1125-1128, 2020.
- [7] 落合桂一, 松尾豊, “因果推論を用いた論文引用関係の分析”, 人工知能学会全国大会論文集 第 36 回, \*pp. 4N1GS301-4N1GS301, 2022.
- [8] 佐野大樹. “日本語アプレイザル評価表現辞書. の構築 評価の多様性を捉えるための言語資源の開発,” 言語処理学会第 17 回年次大会発表論文集, 2011
- [9] Z. Wang, J. Chen, H. Chen, “EGAT: Edge-Featured Graph Attention Network.” ICANN 2021: 30th International Conference on Artificial Neural Networks, p253-264, 2021.
- [10] N. Reimers. “Sentence-BERT: Sentence Embeddings using Siamese BERT Networks.” arXiv preprint, 2019.
- [11] R. Rashid, J. Chowdhury, G. Terejanu. “From causal pairs to causal graphs.” 2022 21st IEEE International Conference on Machine Learning and Applications (ICMLA). IEEE, p. 802-807, Dec.2022.