

(研究ノートNo.2)

# 因果概念束における文意類似度の評価法

— 運転免許学科試験問題への応用 —

鈴木 治  
常葉大学 名誉教授  
E-mail: osuzuki@bi.wakwak.com

## Semantic Similarity Evaluation in Causal Concept Lattices - A Case Study of Driver's License Tests -

Osamu SUZUKI  
Professor Emeritus TOKOHA UNIVERSITY  
E-mail: osuzuki@bi.wakwak.com

### [目次]

1. はじめに
2. 因果概念束の定義と用語
3. 因果概念束における推論
4. 因果概念束における文意類似度の検証
5. 因果概念モデルの検証結果
6. 考察
7. おわりに
8. 参考文献

### 要旨

2020 年, 本研究は形式概念分析を拡張した因果概念束(人の思考過程に近い知識構造モデル)を提唱した。それ以降, 2 分野の因果概念束データベースの活用を通して, 因果概念モデルの推論機構に関する研究を行ってきた。その結果, 因果概念束がもつ知識構造には, 汎用型人工知能(Artificial General Intelligence)の方向性と一致する点が含まれることが分かってきた。本稿は, 運転免許学科試験問題を事例として, 因果概念モデルによる○×問題の正解文抽出とその検証結果について述べる。

キーワード : 形式概念分析, 知識構造, 因果概念束, 因果概念モデル

### Abstract

In 2020, this study introduced the causal concept lattice, an extension of formal concept analysis, as a knowledge structure model closely resembling human cognitive processes. Since then, we have conducted research on the inference mechanisms of the causal concept model using databases in two specific domains. As a result, it has been revealed that the knowledge structure of the causal concept lattice aligns with certain aspects of Artificial General Intelligence (AGI). This paper discusses the extraction of correct answers for true/false questions using the causal concept model and presents the verification results, using driving license theory test questions as a case study.

**Keywords:** formal concept analysis, knowledge structure, causal concept lattice, causal concept model

## 1. はじめに<sup>(1)</sup>

本稿では、教科書文をコンテキストとして形式概念分析に適用し、その結果得られる概念束を因果概念束とよぶ。本研究は、この因果概念束を知識構造モデルの一つとして位置付け、推論やアブダクションへの応用を目指している。2020 年以来、本研究は形式概念分析を拡張した因果概念束(人の思考過程に近い知識構造モデル)を提唱してきたが、これまで 2 分野にわたる教材の因果概念束を生成し、因果概念データベースとして蓄積した。また同時に、因果概念データベースの検索システムも開発し、因果概念束の持つ様々な特性を調査してきた。

ここでは、最初に形式概念分析の概要を述べた後、因果概念束との関係、及び使用する用語の定義を行う。次に質問の文意を因果概念束にマッピングするベクトル表現及び概念束間の文意類似度評価法について述べる。さらに、運転免許学科試験の○×問題を取上げ、因果概念モデルが提示した解答結果について考察する。

## 2. 因果概念束の定義と用語<sup>(2)(3)(4)</sup>

形式概念は、「*The Basic Theorem on Concept Lattices*」(「概念束の基本定理」)にもとづくデータ分析法の一つである。以下では形式概念分析の概要を述べ、因果概念束との関係についても言及する。

形式概念分析は、コンテキストを入力として概念束を生成する分析法の一つである。この概念束の要素は概念とよばれ、それは外延と内包の対から構成される。いま、ある概念を  $(A_j, B_j)$  とすると、その上位概念は、

$$\bigvee_{j \in J} (A_j, B_j) = \left( \left( \bigcup_{j \in J} A_j \right)', \bigcap_{j \in J} B_j \right) \quad (2.1)$$

で表され、一方、概念  $(A_j, B_j)$  の下位概念は、

$$\bigwedge_{j \in J} (A_j, B_j) = \left( \bigcap_{j \in J} A_j, \left( \bigcup_{j \in J} B_j \right)' \right) \quad (2.2)$$

により表される。ただし、 $A_j$  は外延、 $B_j$  は内包とする。

これらの定式化のもとに、2 つのコンテキスト

$K_1 := (G_1, M_1, I_1)$ ,  $K_2 := (G_2, M_2, I_2)$  の概念を  $B_1(G_1, M_1, I_1)$ ,  $B_2(G_2, M_2, I_2)$  とすると、 $B_1$  を上位、 $B_2$  を下位とする概念束は、

$$B_1 \oplus B_2 = B(G_1 \cup G_2, M_1 \cup M_2, I_1 \cup I_2 \cup (G_1 \times M_2)) \quad (2.3)$$

により表わされ、これは垂直和(*vertical sum*)と呼ばれる。また、 $B_1$  と  $B_2$  の並置概念束は、

$$B_1 \cup B_2 = B(G_1 \cup G_2, M_1 \cup M_2, I_1 \cup I_2) \quad (2.4)$$

で表され、並置和(*horizontal sum*)とよばれる。

次の条件を満たすとき、概念束  $B_L$  の部分束  $B_M$  を部分概念束とよぶ。

$\emptyset \neq B_M \subseteq B_L$  のとき、 $a, b \in B_M$  ならば、

$$a \vee b \in B_L \text{ かつ } a \wedge b \in B_L \quad (2.5)$$

一方、概念束  $B_L$  の部分束であるが、部分概念束ではない束は単に部分束とよぶ。

形式概念分析はこれまで固定的なオブジェクト名や属性名を扱ってきたが、この因果概念束では文章を扱うため、文脈や単語語形変化、類似語等への配慮が必要になる。広辞苑では、文を「形の上で完結した一つの陳述によって述べられている言語表現の一単位」と定義し、段落は「長い文章中の大きな切れ目」、文脈は「文章の中で文と文との続き具合」、さらに文意は「文章の表す意味」と定義し、外延は「概念が適用せらるべき事物の範囲」、内包は「諸事物が共通に有する性質の全体」と定義している。本稿ではこの広辞苑の定義に準拠し、以下の用語定義も付け加える。

形式概念分析では、外延と内包の間に *Galois Connection* が成立する。よって、形式概念分析を基礎とする因果概念束においてもこの関係は成立する。また広辞苑の定義のもと、外延(オブジェクト集合)は「事象命題が成立する範囲事象(環境又は状況等)」と拡張し、内包(属性)は「事象命題を構成する性質(すなわち、文を構成する単語集合)」と拡張する。事象命題は複数文(1 文を含む)で構成されるが、ここでは事象命題間に順序関係(因果関係)の存在を仮定する。本研究では、コンテキストデータとして、事象命題を形式概念分析に適用し、生成される概念束を因果概念束と定義する。因果概念束は文脈にほぼ対応するが、文脈情報を束構造として持つことが異なる。因果概念束はコンテキストが入力される度に、それまで蓄積された全ての因果概念束との再編成が行われ、その結果は再びデータベースに反映される。さらに、本研究で扱う因果関係は「前提と結果」、「前事象と後事象」、「過去と未来」、「具体化と抽象化」など、幅広い順序関係を含むものとする。前述の様に、因果概念束は形式概念分析の性質を引き継ぐため、概念の抽象化特性を有し、人間の持つ物事の抽象化や論理思考と類似する性質を持つ。本稿では、誤解のない限り、事象命題を単に「文」とよぶことがある。

後述するが、本稿では因果概念束にベクトルを導入する。このため「単語ベクトル」、「文字ベクトル」及びそれらを合成した「概念ベクトル」、「文(命題)ベクトル」、「段落ベクトル」などの用語も使用する。

## 3. 因果概念束における推論<sup>(5)</sup>

大規模言語モデルとしての生成 AI は、トークンを確率的に選択・結合する言語モデルと考えられ、その出力結果には蓋然性が伴うと言われる。一方、因果概念束は、明示的に与えた事象命題をそのまま因果関係

として取り込むモデルであり、必然的な推論が可能である。例えば、事象命題  $P_1$ ,  $P_2$  の概念をそれぞれ  $B_1$  と  $B_2$  とすると、式 2.3 から、命題  $P_1 \rightarrow P_2$  の因果概念束は  $B_1 \oplus B_2$  と表現され、形式概念分析の性質から因果概念束の下位概念から上位概念への推論は、*Implication Rule* による必然的推論となり、逆に上位概念から下位概念への推論は *Association Rule* による蓋然的推論（アブダクション）となる。この点は、因果概念束と生成 AI との大きな違いである。以下では、簡単な小話「風が吹くと桶屋が儲かる」を例にとり、因果概念束の推論機構を述べる。

### 事例 1 共通環境（外延）の連続した事象命題

図 3.1 に示す事象命題コンテキストは、共通環境（ここでは外延（小話））を持つ因果関係であり、コンテキスト「大風が吹く」から「桶屋が儲かる」が連鎖する事象命題である。但し、図中の「 $\rightarrow$ 」は事象命題の連鎖を示す。図 3.1 をコンテキストとする因果概念束を図 3.2 に示す。同図は、最下位ノードの「大風が吹く」

#### 事例 1

（小話）：大風が吹く $\rightarrow$ 土埃が立つ、土埃が立つ $\rightarrow$ 盲人が増える、盲人が増える $\rightarrow$ 三味線の需要が増える、三味線の需要が増える $\rightarrow$ ネコの皮の需要が増える、ネコの皮の需要が増える $\rightarrow$ ネコが減る、ネコが減る $\rightarrow$ 鼠が増える、鼠が増える $\rightarrow$ 桶が多くかじられる、桶が多くかじられる $\rightarrow$ 桶の需要が増える、桶の需要が増える $\rightarrow$ 桶屋が儲かる

図 3.1 共通環境の事象命題

から上位に向かって垂直和による因果関係の連鎖が示されている。煩雑さを避けるため、ここでは外延と内包の表示は省略し、事象命題のみを表示する（以下、同様とする）。




図 3.2 因果概念束(3.1)

### 事例 2 異なる環境（外延）の事象命題

次に、異なる環境の事象命題の例を示す（図 3.3）。こ

#### 事例 2

（小話 1）：大風が吹く $\rightarrow$ 土埃が立つ  
 （小話 2）：埃が立つ $\rightarrow$ 盲人が増える  
 （小話 3）：盲人が増える $\rightarrow$ 三味線の需要が増える  
 （小話 4）：線の需要が増える $\rightarrow$ ネコの皮の需要が増える  
 （小話 5）：ネコの皮の需要が増える $\rightarrow$ ネコが減る  
 （小話 6）：ネコが減る $\rightarrow$ 鼠が増える  
 （小話 7）：鼠が増える $\rightarrow$ 桶が多くかじられる  
 （小話 8）：桶が多くかじられる $\rightarrow$ 桶の需要が増える  
 （小話 9）：桶の需要が増える $\rightarrow$ 桶屋が儲かる

図 3.3 異なる環境の事象命題

の例では、事象命題「（小話 1）：大風が吹く  $\rightarrow$  土埃が立つ」と「（小話 2）：埃が立つ  $\rightarrow$  盲人が増える」などは、外延が異なる別事象となっている。図 3.3 の因果概念束を図 3.4 に示す。同図では、各概念が帰納概念を仲介して接続されているが、これらは外延が異なる別事象であるため、因果関係の連鎖とは解釈されない。




図 3.4 因果概念束(図 3.3)

### 事例 3 順不同かつ共通環境（外延）の事象命題

次に、共通環境（外延）を持つ複数の事象命題が、文章中ランダムに出現する例を示す（図 3.5）。この事例は事例 2 のコンテキストと類似するが、外延（小話）が共通すること、及び事象命題がランダムに出現することが異なる。図 3.5 の因果概念束を図 3.6 に示す。ここで、同図の因果関係連鎖記号（○印）は、事象命題間に因果関係の連鎖が存在することを示す記号である。この例の様に、事象命題が段落等を超えてランダムに出現しても、因果概念束では因果関係の連鎖が検出され、概念束上に○印が表示される。

### 事例3

(小話):大風が吹く→土埃が立つ, 土埃が立つ→盲人が増える  
 (小話):鼠が増える→桶が多くかじられる  
 (小話):ネコが減る→鼠が増える  
 (小話):三味線の需要が増える→ネコの皮の需要が増える  
 (小話):桶が多くかじられる→桶の需要が増える, 桶の需要が増える→桶屋が儲かる  
 (小話):盲人が増える→三味線の需要が増える  
 (小話):ネコの皮の需要が増える→ネコが減る

図 3.5 共通環境の事象命題(順不同)




図 3.6 因果概念束(図 3.5)

## 4. 因果概念束における文意類似度の検証<sup>(6)(7)(8)</sup>

一般に、質問に答えるためには、その質問の文意を把握していることが前提となる。例えば、学科試験問題の場合、問題の文意を把握できなければ、正解となる教科書文は探すことができない。これまで、本研究では2分野の因果概念データベースを構築し、図 4.1 に示すデータベース検索システムを開発した。この検索システムは、外延と内包を入力欄に直接入力し、因果概念データベースから式 2.2 及び式 2.2 を満たす因果概念束を抽出・表示する機能を持つ。




図 4.1 因果概念束 DB の検索画面

しかし、今回の学科試験問題では、問題文から正解となる教科書文を得るためには、問題文意と因果概念との対応づけ、及び単語の語形変化や同義語などの対応が必要となり、図 4.1 の外延と内包の直接入力には困難になる。このため、問題文意と因果概念束を対応付ける新たな方法が必要となった。以下では、この新たな方法の検討経緯を述べる。検討に当たっては、学科試験問題(471問)と教科書正解文との対応テーブルを用意しておき、各方法ごとに正解文抽出状況を評価した。

### (1) 最長共通部分列(Longest Common Subsequence)

2つのコンテキスト間の共通単語数をもとに文意類似度を測定した。ここでは共通単語数に加え、単語語形変化を考慮した最長共通部分列も評価に加えた。しかし、元の単語長により最長共通部分列の文字数比率が変動するため、この方法は類似度精度が低いことが分かった。

### (2) 外延ごとと内包属性単語の分布

教科書全文を対象に、外延ごとの内包属性の単語分布テーブルを作成し、問題文の単語から教科書文の外延が推定できないか検証を行った。しかし、この単語分布テーブルでは、特徴的な属性単語から外延を特定できるケースが限られ、単語分布テーブルによるコンテキストの類似度評価は効果が低いことが分かった。

### (3) JAWJAWを用いた同意語検索

当初、Web スクレイピングによる同意語検索を用いたコンテキスト間の類似度評価を考えた。しかし、この方法は応答性や API などの制約があるため断念し、代わりに日本語 WordNet を用いた JAWJAW 同意語検索を試行した。しかし、JAWJAW は分野ごとの同義語であり、求めたい単語の分野が分からないと同義語を採せないことが分かった。これは問題文の単語分野検索という新たな課題を伴うためこの方法は断念した。

### (4) 分散表現ベクトルの導入

大規模言語モデルを参考に、外延や内包を構成する単語等のベクトル化を検討した。ベクトル化に当たっては、python 言語を用いた自作の word2vec プログラムを用い、教科書の全単語と文字をそれぞれトークンとする2種類の分散表現ベクトルを計算した。この2種類の分散表現ベクトルを用いて、問題文と教科書文の類似度評価を行った。2種類のベクトルを用いた理由は、①未知の単語が出現した場合、その前後の単語から文意を捕捉できないか、②単語の語形変化があった場合、文字トークンベクトルが語形変化を吸収できないか、の2点である。この結果、因果概念束への分散表現ベクトル導入により、教科書文と問題文の文意類似度の精度は、他の方法に比べて優れていることを

確認した。

#### (5) 概念ベクトルを用いた段落方式

分散表現ベクトルの有用性を確認した上で、次に、単語及び文字ベクトルを合成した文ベクトル（事象命題ベクトル）、概念ベクトル（外延と内包の合成ベクトル）、因果概念束ベクトル（概念束の合成ベクトル）及び段落ベクトル（外延単位の合成ベクトル）を用いた問題文と教科書文の文意類似度を評価した。この結果、特に段落ベクトル方式では、段落文意を総合的に把握できることが分かった。段落ベクトルによる問題文と教科書文の比較結果は、目視による文章比較と比べても高い精度で類似性が得られていることを確認した。

#### (6) 段落ベクトルと因果概念束ベクトルの組合せ

前述の段落ベクトル方式（以下、段落方式という）は、段落レベルの総合的な文意による抽出方法である。しかし、今回の学科試験の○×問題では、文レベルの誤りや矛盾を指摘することが求められ、段落単位は文意が総括的で範囲も広すぎ、文単位の文章比較を行うには無理があった。逆に、教科書の全文全ての因果概念束ベクトル方式は、それらを保持し、問題文と照合する計算コストが大きすぎる。そこで(5)を改良し、段落ベクトルと概念束ベクトルを組み合わせた2段階方式

（以下、2段階方式という）を検討した。この2段階方式は、最初に問題文の文意に類似する教科書段落（段落は外延に相当する）を抽出し、その類似度上位の段落の中から、問題文の文意と高い類似度を持つ因果概念束（教科書文に相当する）を抽出する方法である。検証の結果、2段階方式は、問題文の文意と高い類似度をもつ教科書文を直接抽出できることが確認された。

以上の結果を整理すると、段落方式は質問文の総括的な文意を問う説明問題に適し、2段階方式はそれより細かい文単位の間違いや論理矛盾を問う問題に適していることが明らかになった。

#### (7) Attention機構による補正

教科書文と問題文を構成するそれぞれの単語間の結び付き強度に着目し、各概念束の Attentionベクトルによる補正を行い、両者間の類似度を測定した。しかし、Attentionベクトル補正を行ったにもかかわらず、類似度の顕著な精度向上は認められなかった。今回は、ChatGPTと Gemini それぞれから Attentionプログラムを参照し、コード検証も行ったが、自作プログラムではないため誤謬がないとは言い切れない。この原因は今後の検討課題とする。

#### (8) Position Encording による補正

因果概念束の外延と内包を構成する単語間の位置関係に着目し、それぞれの単語位置ベクトル（cos 値

と sin 値の組合せ）補正を行い、両者間の類似度を測定した。しかし結果として、文意の類似度に顕著な精度向上は認められなかった。ここでも ChatGPT と Gemini からそれぞれ Position Encording プログラムを参照しコード検証も行ったが、自作プログラムではないため誤謬がないとは言い切れない。これも今後の検討課題とする。

#### (9) Position Encording と Attention機構の組合せ

因果概念束の外延と内包を構成する単語の出現順序と単語間の結び付き強度に着目して、教科書文及び問題文の類似度を測定した。具体的には、それぞれに Position Encording を行った後、Attention機構によるベクトル補正を行い、両者間の文意類似度を測定した。しかし、この方法においても文意の類似度精度の向上は認められなかった。使用したプログラムは(7)、(8)と同じである。

### 5. 因果概念モデルの検証結果<sup>(9) (10) (11)</sup>

本稿では、因果概念束データベースとその活用機能を含め、因果概念モデルと呼ぶことにする。ここで因果概念モデルを検証する前に、因果概念モデルの諸元を表 5.1 に示しておく。

表 5.1 因果概念モデルの諸元

| 項目       | 諸元                                                                                                             |
|----------|----------------------------------------------------------------------------------------------------------------|
| 教科書      | 「学科教本 統合版」トヨタ名古屋教育センター発行No. 20B-0715-751.5 令和2・6・30改訂版 A4判341 ページ                                              |
| 教科書データ   | 単語数：2,202, 文字数：953, オブジェクト数：527, 属性数：2,990, 段落数：604, 因果概念束数：1,508                                              |
| 問題集      | 「普通免許 テキスト&速攻集」成美堂出版, 2020年8月30日                                                                               |
| 問題データ    | 全問題数：471, 対象問題数：419, 除外問題数（イラスト, 保守分野）：52                                                                      |
| 因果概念数    | 総概念数：5,797, 演繹概念数：2,839 帰納概念数：2,958                                                                            |
| システムの概要  | OS:Windows10, データベース：Microsoft Access, プログラム言語：java, python, ハードウェア: Intel (R) Core (TM) i7-8700 CPU @ 3.20GHz |
| 分散表現ベクトル | vector size:200, window size:50, min count:1, model:CBOW, iter:100                                             |

前章で述べた(1)から(9)をまとめると、問題文の文意に近い教科書文の抽出評価では、(1)～(3)は類似度精度が低く、(7)～(9)も複雑な処理の割には顕著な類似度精度が認められなかった。この結果、(6)が問題文の文意に最も近い教科書文の抽出可能な方法であるこ

とが分かり、運転免許学科試験〇×問題には2段階方式が最も望ましい方法であると判断した。

しかし、〇×問題以外の説明問題などでは、段落方式が有利であることも考慮し、以下では段落方式と2段階方式について、運転免許学科試験問題を例にとって検証結果とその考察を述べる。

一般に、教科書(テキスト)は、章、節、頁、目等のレベルから構成される。今回使用した運転免許学科試験の教科書では、例えば章レベル「最高速度」は、その下の節レベル「規制速度と法定速度」などから構成され、以下、頁レベルは「規制速度と法定速度」など、そして目レベルは「規制速度」や「法定速度」などから構成される階層的な記述構成となっている。特に目レベルの「規制速度」などは、概ね数十行の文章や表や図から構成されており、本稿ではこの目レベルを1つの段落と見なして段落ベクトルを計算した。また問題文は、単文、複数文を問わず、1問を1段落として段落ベクトルを計算した。

以下では、前著「研究ノート」との対比を考慮し、問題テーマ「踏切での故障」〇×問題を再び事例に取り上げ、上記2方式について具体的な検証を行う。

#### (問題文) 【〇×問題】

「踏切で故障したときは、まず車の移動などの処置をして、その後に踏切支障報知装置を押すとよい。」

最初に段落方式を用いて、問題に正解を与える教科書文の抽出結果を検証する。この方式により得られた因果概念束を図5.1に示す。以下では、煩雑さを避けるため、図中の外延と包内の表示は省略する。




図5.1 段落方式の因果概念束

図5.1の{踏切,故障}は、踏切故障に関する段落名(因果概念束では外延に対応する,以下同様)を示し、{問題文}は問題文段落を示す。同図は、因果概念モデルが第一候補として提示してきたものであるが、問題文の概念束を除けば、図中に3つの因果概念束(①,

②, ③)が含まれるが、それらのテキストを列举すると次のようになる。

外延:「踏切,故障」

内包:「踏切で車が動かないときは、踏切支障報知装置、非常ボタンを押し、列車の運転手に知らせ、車を踏切の外へ移動する。二輪車は降りて踏切の外へ押し出す。四輪車はロー、セカンド、バックに入れ、クラッチを踏まない。セルモータを回し続け、車を移動する。オートマチック車はこの方法が使えない。」

上記は、3つの因果概念束のテキスト部分の列举であるが、この段落は、踏切で故障したときは、まず運転手に知らせること、2輪車の場合の対応、そして4輪車の移動方法など、踏切での故障における総括的な説明文となっている。しかし、〇×問題に答えるには、この記述内容の範囲は広すぎる。事実、この問題の正解文は、①の「踏切で車が動かないときは、踏切支障報知装置、非常ボタンを押し、列車の運転士に知らせ、車を踏切の外に移動する。」であり、〇×問題を解くにはこの3つの因果概念束から①を選ぶ必要がある。この場合は、たまたま最初(0番目)の段落にこの正解文が含まれているが、471問全てについて同様の検証を行ってみると、段落類似度の高い段落に正解文がなかったり、逆に類似度の低い段落に正解文が含まれることもあった。これは、段落方式が問題文意を総括的に解釈して、段落抽出を行っていることの証である。

次に、2段階方式を検証する。2段階方式は、最初に問題文と教科書段落の文意類似度の高い順に上位50位までの段落を抽出する。次に、抽出された段落全ての因果概念束と問題文との類似度を再評価し、得られた因果概念束を類似度の降順に整列する。この結果、因果概念モデルが提示した最初(0番目)の因果概念束が図5.2である。




図5.2 2段階方式の因果概念束

同図は、前著「研究ノート」で述べた手作業による結果と符合している。図中のAとBは、○×判定の根拠となる帰納概念であるので、あらためてそれらの外延と内包を下記に示す。

帰納概念A={ {踏切, 故障, QST}, {車, 踏切支障報知装置, 押す, 移動} }

帰納概念B={ {踏切, 故障, QST}, {踏切, 車, 踏切支障報知装置, 押す, 移動} }

ここで、帰納概念Aの{踏切, 故障, QST}は外延オブジェクトを、{車, 踏切支障報知装置, 押す, 移動}はその内包属性を示す。なお、QSTは問題文を示す外延名である。図5.2のAとBは、教科書文と問題文との共通属性を持つ帰納概念であるが、両者とも「踏切支障報知装置を押す、車を移動する」は共通している。ここで、帰納概念Aから下位方向に演繹概念まで辿ると、教科書文の「踏切支障報知装置、非常ボタンを押す」に辿り着き、問題文からは「車の移動などの処置をする」に辿り着く。これは「車の移動」と「踏切支障報知装置の非常ボタンを押す」の因果関係(順序関係)が逆転しており、命題間に矛盾があることを示している。この矛盾は前著「研究ノート」で指摘した○×判定の根拠と一致する。この様に、○×問題では、得られた教科書文と問題文それぞれの概念束において矛盾があれば×、矛盾がなければ○判定を下すことにより、正解が得られることが分かる。但し、このアルゴリズム実装は今後の課題とする。

これまで問題文との文意類似度による教科書文抽出の検証結果を示した。次に、この2方式の教科書文抽出精度の定量的な分析を行う。

最初に、段落方式における教科書文抽出の定量的な特性を図5.3に示す。同図は、段落数604の内、正解を含む段落が80%の確率で27番目以内に入ること示している。また、正解文が0番目、つまり最初の段落に現れる確率は、約50%であることを示す。




図 5.3 段落方式の抽出特性

次に、2段階方式による教科書文抽出の定量的な特性を図5.4に示す。同図は、因果概念束数1508中、正解文は80%の確率で11番目以内に入ること示している。つまり、抽出された因果概念束を上位から12個調べれば、正解となる教科書文が確率80%で見つかることを示す。また同図は、正解文が最初に見つかる確率が約40%であることも示している。




図 5.4 2段階方式の抽出特性

図5.3と図5.4を比較すると、前者は正解文を含む段落の確率であり、正解文の出現確率ではない。よって、正解文を得るには、27段落の全ての因果概念束を再評価する必要がある。これは、問題を解くときに因果概念束を探す処理が必要になることを意味する。一方、後者は正解文の出現確率であるため、因果概念モデルが提示する正解文と問題文は直接対比可能であり、○×判定処理を簡素化することが可能となる。

## 6. 考察

運転免許学科試験○×問題を事例として、因果概念モデルを用いた正解文の抽出を行った結果、以下のような知見と課題を得ることができた。

### (1) 小規模学習データにおける文意の類似度評価

人は未知の単語に遭遇すると、しばしば会話等の文意が理解できないことがある。まして、機械がそれを行おうとすればなおさらである。本研究においても、教科書にない単語が問題文中に現れた場合、その問題の問うている内容または問題主旨を把握するために多くの試行錯誤を行った。例えば、シソーラスの利用やJAWJAWによる同義語検索を検討したが、同義語の対象ドメイン依存性は新たな課題を惹起した。しかし考えてみると、人は生成AIの様な膨大な文書データの学習は行わなくても、問題文の前後関係から文意を推論したり、内容の抽象化・一般化を行って質問内容をある程度理解してしまう。本稿では、少ない学習データの制約下、どの様に質問の文意を把握すべきかを模

索した結果、因果概念束における分散表現ベクトルの導入と、2段階方式による正解文抽出方式に辿り着いた。但し、これらの方法の背景には、因果概念が2組対（外延と内包）から構成され、この間に *Galois Connection* があることをここで付け加えておく。しかし、この方式であっても、問題文の未知単語がさらに多く出現すれば、正解文の抽出は遠のいてしまう。もしこの問題が紙面ではなく、対話形式であれば因果概念モデルが質問者に対し未知単語を問い直したり、その単語の説明や言い直しを求めれば、この種の問題は解消される可能性が高い。この方法は、まさに生成AIのプロンプトそのものであり、彼らはこの先進的かつ巧妙な方法を既に編み出してきたと言える。

## (2) 正解文の抽出確率が100%に満たない問題

5章で述べたように、問題文に正解を与える教科書文は、因果概念束の上位12個を調べれば80%の確率で得られる。しかし、抽出不能を含め、13番目以降は20%の確率で誤解答となる可能性がある。この問題は、小規模学習データでの文意理解の難しさに原因があると思われるが、これは(1)と共通した問題でもある。

(3)なぜ、*Attention*機構及び*Position Encoding*は機能しなかったか

生成AIは、*Transformer*、*Attention*機構、*Position Encoding*及び強化学習などの様々な技法を駆使し、あたかもシステムが文意を理解しているかの様子を振る舞いを見せている。本研究は、この優れた技術の一端を試行的に取り入れて検証を行ったが、残念なことに顕著な成果は見いだせなかった。これには学習データの不足やその他の要因も考えられるが、この原因究明は今後の課題として残しておきたい。

以上、本稿には幾つかの重要な課題が残された。しかし、これらの課題の中には、汎用型人工知能の本質に関わるような課題も含まれている。今後は、因果概念モデルを用いて、人の思考に近い汎用型人工知能、特に論理的推論の実現に力を注ぎたいと考える。因果概念モデルは、命題論理にもとづく推論や数学分野での応用にも期待が持てる。これまで蓄積してきた因果概念データベースを活用し、そこから因果関係の連鎖による新たな知識やアブダクションの発見も試みたいと考えている。

## 7. おわりに<sup>(12)</sup>

2022年11月、生成AIはマイクロソフト社の*ChatGPT*の公開に始まり、以来、破竹の勢いで世界を席卷した。さらに、生成AIに付随するGPU半導体製造企業も、世界経済を牽引する急成長を見せた。しかし一方、マス

コミ等では、生成AIの膨大な学習量やハードウェアコスト、消費電力そしてハルシネーションや著作権など、種々の問題が報じられた。また近年、米国では失業問題、電力獲得競争、生成AI投資への疑義と株価下落など、負の側面も見せ始めている。大規模言語モデルとしての生成AIは、人の知識や言語能力を凌駕するとも言われる。しかし、生成AIによる天文学的な計算コストは、人間の知識処理コストと比べて大きく乖離しているようにも思われる。モントリオール大ヨシュア・ベンジオ教授は、「現在のAIは人間と比べて、論理的思考や数学的能力が著しく劣っている」とも述べている。

世界は今、汎用型人工知能の開発競争に凌ぎを削っているが、大規模言語モデルの開発競争ではこれまで我が国は、世界に後れを取ってきた経緯がある。我が国が再びこのような轍を踏まないためにも、今、我々は人の思考に近い人工知能の研究開発に、国を挙げて取り組まなければならない時にあると考える。本研究は、汎用型人工知能アーキテクチャとしての因果概念モデルの実用化を目指し、今後とも一層の努力を重ねていきたいと考えている。

## 8. 参考文献

- (1) 鈴木 治, 室伏俊明, 「形式概念分析—入門・支援ソフト・応用—」, 日本知情報ファジィ学会, 日本知能情報ファジィ学会誌 19(2), pp. 103-142, 2007
- (2) 新村 出編, 広辞苑第2版補訂版, 岩波書店, 1979
- (3) 文脈とAI, 堀 浩一 石崎 旬, 人工知能学会誌 P312-318, Vol 3, No3, 1988
- (4) 鈴木 治, 「因果概念束にもとづく知識構造モデルの研究」, 常葉大学経営学部紀要, 第8巻第2号, pp. 1-11, 2021
- (5) 鈴木 治, 「(研究ノート) 因果概念束を用いた知識構造モデルの応用」,  
[http://park23.wakwak.com/~osuzuki/thesis/2022\\_12\\_note.pdf](http://park23.wakwak.com/~osuzuki/thesis/2022_12_note.pdf)
- (6) 嶋英樹, 「JAWJAW: Java Wrapper for Japanese WordNet」, 2013年3月  
<https://www.cs.cmu.edu/~hideki/software/jawjaw/>
- (7) OpenAI, ChatGPT, 「The algorithm of Position Encoding and Attention mechanism.」, 2024年3月
- (8) Google, Gemini, 「The algorithm of Position Encoding and Attention mechanism.」, 2024年8月
- (9) (トヨタ名古屋教育センター, 「学科教本 統合編」, 2020
- (10) 長 信一, 「普通免許 テキスト&速攻問題集」, 成美堂出版, 2020

(11)一般財団法人 全日本交通安全協会 編集・発行,  
「わかりやすい道路交通法」, 2019

(12) 日本経済新聞, 「速さより「熟考」する AI」,  
2024 年 9 月 14 日

(2025/1/4 執筆)

(2025/1/14 誤植訂正)