

# 計算機モデルによる Open-end な状況での認知の分析

## A Computational Analysis Model for Open-ended Cognitions

森田 純哉  
Morita Junya

名古屋大学人間情報学研究科  
Graduate School of Human Informatics  
morita@cog.human.nagoya-u.ac.jp

三輪 和久  
Miwa Kazuhisa

名古屋大学情報科学研究科  
Graduate School of Information Science  
miwa@cog.human.nagoya-u.ac.jp, <http://www.cog.human.nagoya-u.ac.jp/~miwa/>

**keywords:** cognitive science, open-ended data, cognitive modeling, analogical reasoning.

### Summary

In this paper, we propose a novel usage for computational cognitive models. In cognitive science, computational models have played a critical role of theories for human cognitions. Many computational models have simulated results of controlled psychological experiments successfully. However, there have been only a few attempts to apply the models to complex realistic phenomena. We call such a situation “open-ended situation”. In this study, MAC/FAC (“many are called, but few are chosen”), proposed by [Forbus 95], that models two stages of analogical reasoning was applied to our open-ended psychological experiment. In our experiment, subjects were presented a cue story, and retrieved cases that had been learned in their everyday life. Following this, they rated inferential soundness (goodness as analogy) of each retrieved case. For each retrieved case, we computed two kinds of similarity scores (content vectors/structural evaluation scores) using the algorithms of the MAC/FAC. As a result, the computed content vectors explained the overall retrieval of cases well, whereas the structural evaluation scores had a strong relation to the rated scores. These results support the MAC/FAC’s theoretical assumption - different similarities are involved on the two stages of analogical reasoning. Our study is an attempt to use a computational model as an analysis device for open-ended human cognitions.

### 1. はじめに

認知科学の目標は人の認知の理解であり、その主要な手法が「心理実験の実施」と「計算機モデルの利用」であった。そこでは、人を対象とした心理実験が行われ、その結果が計算機モデルによって説明される。逆に、モデルの予測から新たな心理実験が実施され、モデルが改善されていく。このように、認知科学の典型的な発展のプロセスは、心理実験と計算機モデルの循環的な利用であった。ここにおいて、計算機モデルは、人の認知を説明する“理論”の具体化として、重要な役割を果たしてきた。

本稿では、計算機モデルを“アルゴリズム”、“知識”、“パラメータ”の3つの構成要素からなるものと捉え、その利用の方法を議論する。ここでいうアルゴリズムとは、明示化された情報処理の手続きであり、知識とはアルゴリズムに対するデータベースである。そして、パラメータとは、アルゴリズムの利用を制御する変数を意味する。アルゴリズムがモデルの基礎的な要素であるのに対し、

知識の内容とパラメータの値はモデル中では可変的な要素となる。

従来、計算機モデルは“シミュレーション装置”として利用されてきた。例えば、ACT-R や Soar などの認知アーキテクチャを利用した研究では、アーキテクチャに備わるアルゴリズムの上に、知識とパラメータの値が設定される。知識とパラメータの値はモデルの背景となる理論に即して設定され、モデルは理論の具体化となる。知識とパラメータの値の設定に続いて、モデルは人と同型の課題を遂行する。人とモデルの振る舞いが類似すればするほど、モデルを構成する知識やパラメータの値の蓋然性が高くなり、背景となった理論の妥当性が示される(認知アーキテクチャに関する近年のレビューは [Anderson 03, Ritter 04])。

本稿では、上記のようなシミュレーションとは異なる計算機モデルの利用法を提案する。我々は、心理データに対する“分析装置”としての計算機モデルの利用を考えた。つまり、心理実験で人から得られるデータを計算機

モデルに入力し、モデルのアルゴリズムを通したデータの定量化を行う。その結果から、人の認知を説明する上での適切な知識やパラメータの値を同定する。このような手法は従来の計算機モデルの利用と異なるロジックにある。図1は従来の手法と分析装置としての計算機モデルの利用について、その差異をまとめたものである。シミュレーションが知識とパラメータの値の仮設的設定の後に人とモデル間での出力の間接的な対応付けを行うのに対し、分析装置としての計算機モデルの利用では、心理データがモデルに対する直接的な入力となり、その結果から知識やパラメータの値が推定される。

我々は、分析装置としての計算機モデルの利用は、現実的な状況での認知を理解する上で利点があると考え、シミュレーションを行うためには、基本的に、課題の遂行に必要な知識とパラメータの値を事前に設定する必要がある。しかし、人が日常生活において学習する知識の数は膨大であり、必要な知識の全てをモデルに事前に入力することが困難な状況がある。本稿では、利用される知識を事前に設定することが困難な状況を Open-end な状況と呼び、Open-end な状況で得られる心理データを分析する装置として計算機モデルを利用した研究を示す。

本研究では、類推を対象領域として、その代表的な計算機モデルである MAC/FAC モデル [Forbus 95] を取り上げ、上記の手法を適用する。類推とは類似した事例との対応付けによる推論であり、意思決定 [Markman 01]、問題解決 [Gick 80]、科学的発見 [Gentner 93a] など多様な認知活動に関与するとされる。過去、類推は認知科学において盛んに研究されてきた。その出発点が、類推に関与する類似性を区別した構造写像理論 [Gentner 83] であった。それに続いて、理論の仮定する類似性を計算機上に実装したモデル [Falkenhainer 89, Forbus 95] が開発された。それらは心理実験とシミュレーションの積み重ねを通して評価され [Markman 93, Gentner 93b, Markman 97]、現在に至るまでモデルの改善が進んでいる [Forbus 01]。以下、我々の研究を示す前に、類推研究の大まかなレビューを行う。その後到我々が行った実験と分析の手法を示し、結果に基づいて、本研究のインプリケーションを示す。

## 2. 認知科学における類推研究

### 2.1 類推の理論 -構造写像理論-

構造写像理論 [Gentner 83] は過去 20 年間の類推研究における支配的なフレームワークであった。構造写像理論では、類推に関与する事例として、“ターゲット”と“ベース”を区別する。ターゲットは直面する状況を意味し、ベースはターゲットと類似した過去の事例である。類推は、ターゲットを手がかりとして記憶中のベースを想起し、想起したベースを利用してターゲットに関する推論を行う一連のプロセスとされる。

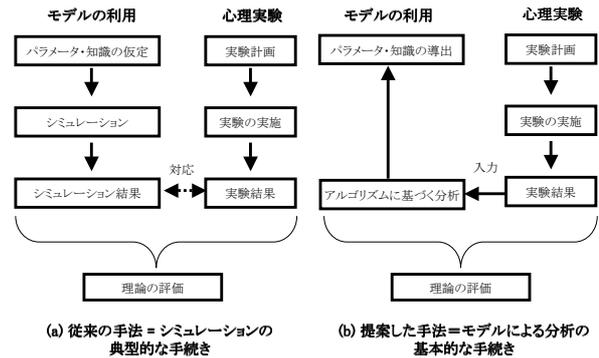


図1 分析装置としての計算機モデルの利用法。

類推のプロセスはターゲットとベースの類似性によって媒介されるものと捉えられる。構造写像理論では命題形式（述語-引数による定式化）による知識表現を仮定し、命題中の述語の対応によって事例間の類似性を表現した。述語の対応としては以下の三種類が区別された。

- 属性の対応 (Object attributes)  
ex. 太陽は赤い みかんは赤い [red (sun) red (orange)]
- 1 階の関係の対応 (First-order relations)  
ex. 太陽の周りを惑星が回る 原子核の周りを電子が回る [revolve-around (planet, sun) revolve-around (electron, atom)]
- 高次の関係の対応 (Higher-order relations)  
ex. 太陽が惑星を引きつけることで太陽の周りを惑星が回る 原子核が電子を引きつけることで原子核の周りを電子が回る [cause (attract (sun, planet), revolve-around (planet, sun)) cause (attract (atom, electron), revolve-around (electron, atom))]

これらの区別は、各々の述語の引数による区別である。“属性”と“1 階の関係”は共に“みかん”、“惑星”、“太陽”などの“オブジェクト”を引数とし、引数の数によって 2 つの述語は区別される（属性は単一のオブジェクトを、1 階の関係は複数のオブジェクトを引数とする）。“1 階の関係”と“高次の関係”は共に複数の引数をとるが、関係構造の複雑さと深さが異なる（高次の関係はオブジェクトを引数とせず、“下位命題”を引数とする）。

以上の区別に基づいて、類推のプロセスに関与する二種類の類似性が以下のように定義された\*1。

- 表層的類似性 (Surface similarity)  
ターゲットに含まれるオブジェクトとベースに含まれるオブジェクトとの類似性とされる。命題上では、オブジェクトを引数とする述語（属性、1 階の関係）の共有量として表現される。
- 構造的類似性 (Structural similarity)

\*1 [Gentner 83] の主眼は“構造的類似性”の定義であって、“表層的類似性”という言葉は実際は用いらなかった。本稿の“表層的類似性”の定義は [Gentner 93b], [Forbus 95] に基づく。

ベース構造からターゲット構造への写像 (mapping) の大きさとされる。“構造”とは、関係的述語 (1 階の関係, 高次の関係) を媒介とした命題要素間 (オブジェクト, 述語) の結合を意味する。“ベース構造からターゲット構造への写像”とは、ベース中の各々の命題要素をターゲット中の各々の命題要素へ構造的に一貫して対応付けることを意味する。“構造的に一貫した対応”とは、「引数の位置 (第 1 引数, 第 2 引数...) に従った対応付けをすること」, 「単一の命題要素を複数の命題要素に対応付けないこと (一対一対応の制約)」という 2 つの制約に従ったものとされる。

構造写像理論の主張は二種類の類似性 (表層的類似性, 構造的類似性) の形式的な区別であり, 人は二種類の類似性を使い分けて類推を行うとする。とりわけ, 構造的類似性の計算は, 表層的類似性の計算に比べ, 複雑な処理を要するため, 類推の後期の処理 (意識的な処理) で重要になるとされる。つまり, 人は構造的に類似したターゲットとベースの組み合わせを類推として良いものだと感じ, 構造的類似性に従った推論を好むとされる。

## 2.2 類推の計算機モデル -MAC/FAC モデル-

MAC/FAC モデル [Forbus 95] は構造写像理論における類似性の区別を計算機上に実装し, 人の類推のプロセスを包括的に説明したモデルである。構造写像理論から導かれる MAC/FAC モデルの重要な理論的仮定は, 「表層的類似性が関与する事例の検索段階」, 「構造的類似性が関与する事例の評価段階」という 2 段階の類推のプロセスの区分である。なお, 本稿の目的は MAC/FAC モデルを紹介することではないので, 以下の説明は概略的なものである (詳細は [Forbus 95] を参照)。

MAC/FAC モデルのはじめの段階は MAC (Many are called) 段階と呼ばれる。MAC 段階とは, ターゲットを手がかりとし, 記憶プールから複数のベース候補を大雑把に抽出する段階である。この段階では, 膨大な記憶プールから速やかにベース候補を検索する必要がある。そのため, MAC 段階では計算コストの低いチープな表層的類似性に基づく検索が行なわれるものと [Forbus 95] は仮定した。MAC/FAC モデルでは表層的類似性を計算するために, Content Vector (CVector) と呼ばれる事例中の述語の頻度を表すリストが定義された。表層的類似性は, 2 つの CVector の内積によって算出され, 内積の高い事例が MAC 段階において抽出されることになる (以降, CVector の内積の値を CVector 値と呼ぶ)。

なお, CVector とは特徴ベクトルの一種であり, 属性と関係的述語の区別がなされないリストである。よって, CVector 値は属性と 1 階の関係の対応の両方に影響される。また, CVector は要素間の結合関係を表現しないため, 因果関係が逆転した事例間の CVector 値や, オブジェクト間が一対一に対応しない事例間の CVector 値が

過剰に見積もられる。例えば, 「戦争の結果, 平和になった」というストーリーと「平和の結果, 戦争が起きた」というストーリーは CVector 上で区別されない。また, 「2 匹の犬同士の争い」という記述に対して, 「2 匹の狼同士の争い (一対一対応)」よりも, 「3 匹の狼同士の争い (一対多対応)」の CVector 値が高く見積もられる。

MAC 段階で抽出された候補は FAC (Few are chosen) 段階において, 更に評価される。FAC 段階とは, MAC 段階において抽出されたベース候補を詳細に評価する段階であり, [Forbus 95] は, ここにおいて構造的類似性が関与すると考えた。MAC/FAC モデルでは, SME モデル [Falkenhainer 89] によって, 構造的類似性の指標が算出され, 事例が評価される。SME モデルとは構造写像理論が定義する構造的類似性を忠実に計算する類似性計算のアルゴリズムであり, 以下の 2 ステップを含む。

*Local match* の構成: ターゲットとベース候補に含まれる個々の述語が対応付けられる。各々の対応は Local match と呼ばれる。その際, 同一の名前をもつ述語のみが対応付けられ, 異なる名前の述語は対応付けられない (例えば cause は cause とのみ対応付けられ, その他の述語とは対応付けられない)。その後, それぞれの Local match 間の一貫性に応じ, 個々の Local match に数値化された重みが割り振られる。

*Global match* の構成: 各々の Local match は一対一対応の原則 (同じ要素を複数の要素に対応付けない) を満たす形で結合され, ベースとターゲットの全体的な写像 (Global match) が構成される。Global match に含まれる Local match の重みが加算されることで, 写像の大きさを示す “Structure Evaluation Score (SES 値と呼ぶ)” が計算される。

つまり, SME モデルとは, 構造的に一貫した写像を実施し, 写像の大きさに応じた類似性を計算するものである。そのため, 因果関係の逆転した事例間の SES 値は常に低く見積もられ, オブジェクト間の対応が一対多になる事例間の SES 値が高く見積もられることはない。

以上が MAC/FAC モデルの概要である。冒頭で述べた用語に従えば, MAC/FAC モデルは, CVector の内積の計算, SME モデルという二種類の類似性計算の “アルゴリズム” を含むものと捉えられる。記憶プール中には事例が “知識” として含まれ, MAC 段階と FAC 段階を経ることで, 事例が想起され, 評価される。そして, MAC/FAC モデルの “パラメータ” は, 各段階における CVector 値と SES 値の関与の度合い (広い意味での重み) と捉えられる。[Forbus 95] による MAC/FAC モデルの理論的仮定は, 「MAC 段階における CVector 値の独占的な関与」, 「FAC 段階における SES 値の独占的な関与」というパラメータの値の設定によって実装されることになる。

2.3 類推研究における心理実験とシミュレーション

[Gentner 93b] は MAC/FAC モデルの理論的仮定を検証する心理実験を実施した。彼女らはベースとターゲットに相当するものとして短いストーリー (100 個) を用いた。100 のストーリーはそれぞれ 5 つのストーリー (1 つのベースストーリー、四種類のターゲットストーリー) からなる 20 のセットから構成された。それぞれのセットはオリジナルとなるベースストーリー、ベースストーリーと属性と 1 階の関係を共有するターゲットストーリー (Surface Similarity - SS と呼ばれた)、1 階の関係と高次の関係を共有するターゲットストーリー (Analogy - AN と呼ばれた)、属性、1 階の関係、高次の関係を共有するターゲットストーリー (Literal Similarity - LS と呼ばれた)、1 階の関係のみを共有するターゲットストーリー (First-order relation - FOR と呼ばれた) を含んだ。

実験において被験者は、まず、20 のベースストーリーを学習した。その 1 週間後にターゲットストーリーが 1 つずつ示され、ターゲットストーリーを手がかりとしたベースストーリーの再生テストが行われた。結果、属性を共有しない AN, FOR を示されたときより、属性を共有した LS, SS を示されたときで、成績が良くなった。一方、高次の関係を共有しない SS, FOR に比べ、高次の関係を共有する LS, AN は、わずかに多くベースを再生させたものの、その差は有意とならなかった。つまり、ベースを想起させる手がかりとしての有効性は、 $LS = SS > AN = FOR$  という順序であったことが示された。この結果は、類似性に基づく事例の検索に“表層的類似性”が関与することを示すものであった。

上記の再生テストに続いて、彼女らの実験の被験者は、ベースストーリーとターゲットストーリーを一緒に呈示され、ストーリー間での“類推としての良さ”を評定した。被験者は“類推としての良さ”について、「あるエピソードを利用して、他のエピソードについて思考をするときに役立つ度合い」と説明された。結果、高次の関係を共有する LS, AN は、高次の関係を共有しない SS, FOR に比べ、高い評定を受けた。一方で、属性を共有する LS, SS と属性を共有しない AN, FOR の評定値に有意な違いは認められなかった。つまり、 $LS = AN > SS = FOR$  の順序で“類推としての良さ”の評定が良くなったことが示された。この結果は、類推の評価に“構造的類似性”が関与することを示すものであった。

[Gentner 93b] は、以上の結果に対して、MAC/FAC モデルを利用したシミュレーションを行った。まず、心理実験で用いられたストーリーが命題表現に変換された。そして、四種類のターゲットストーリー (LS, AN, SS, FOR) が含まれる記憶プールが作成され、ベースストーリーを手がかりとした検索を MAC/FAC モデルに行わせた\*2。その結果、再生率は  $LS = SS > AN = FOR$  の順

あるところに 2 つの国がありました。一方は民主国家で、他方は君主国家でした。民主国は国家としての歴史は浅いものの、経済的に優れ、情報産業が盛んでした。また、とても自由な国でした。君主国は古い歴史をもち、人口が多く、重工業が盛んでした。また、とても勤勉な国でもありました。民主国の国土は東方に位置し、君主国の国土は南方に位置していました。君主国の国土も民主国の国土も素晴らしい土地でした。民主国の国土は年中、涼しく、カラリとしていて、果物の生産が盛んでした。君主国の国土は冬でもそれほど寒くなく、海では一年中泳ぐことができ、穀物の生産が盛んでした。民主国は観光や貿易によって君主国の国土から利益を受けていました。君主国も同じように民主国との交流から利益を受けていました。お互いの利益から、民主国と君主国は何十年間も平和な関係にありました。しかし、君主国は民主国との交流を続けるうちに、民主国の国土を自国の物にすることを望みはじめました。そして、「民主国にミサイルを撃ちこんで攻撃すれば、その望みは叶うだろう」と考えました。ある年、君主国は民主国への攻撃を始めました。君主国の攻撃により、民主国の都市が破壊されました。ダメージを受けた民主国は攻撃をやめるように君主国に通達しました。しかし、民主国の国土を狙う君主国はそのような通達を無視しました。民主国は君主国を恨みました。その数ヶ月後、民主国は君主国に対して反撃を始めました。お互いの攻撃によって戦争が始まりました。君主国の野望が戦争を導いたのです。

図 2 ターゲットストーリーの例。

序となり、人の検索と同様の結果になった。さらに、入力された全てのセットについて、ベースストーリーと AN との SES 値はベースストーリーと SS との SES 値に比べて高くなった。この結果は MAC/FAC モデルのアルゴリズムが人の類似性の感覚と適合し、かつ、MAC/FAC モデルの主張を支える類似度利用のパラメータの値の設定が、人の類推検索のプロセスを説明する上で適していることを示している。

2.4 従来の類推研究の限界

ここまでのレビューが示すように、類推研究は認知科学の典型的な発展のプロセスを辿ってきた。人の類推のメカニズムに関する理論 (表層的類似性と構造的類似性の区別) を背景として、理論を具体化したモデル (チップな表層的類似性に基づく検索/複雑な構造的類似性に基づく評価) が構築された。そして、心理実験のシミュレーションによって理論の妥当性が保証された。

しかし、我々は、現実的な状況での理論の妥当性を、[Gentner 93b] のような研究から示すことは困難であると考ええる。彼女らの心理実験において、被験者は想起すべき事例を実験者から与えられた。また、彼女らのシミュレーションにおいて、事例検索と事例評価のそれぞれに利用される類似度利用のパラメータの値は研究者によって事前に割り振られ、モデルは研究者によって作りこまれた記憶プール中の事例を検索した。被験者 (あるいはモデル) の想起するベースは研究者が作成したものであり、被験者が日常で学習した事例 (研究者の知らない事例) ではなかった。それに対し、現実場面の類推はどのよ

\*2 心理実験と異なり、ベースを手がかりとしてターゲットを想起させるという状況になっている。これは、ベースに比べ、

ターゲットは種類が多く、巨大な記憶プールを作成するのに適していたためである。

うな知識がベースとなるかを予測できない Open-end な状況である。より広い場面での類推のメカニズムを理解するためには、被験者にベースを呈示しない状況での類推を検討する必要がある。

### 3. 心理実験の方法

我々は、[Gentner 93b] とは異なり、被験者にベースとなる事例を学習させない実験を実施した。つまり、被験者がどのような事例を保持し、どのような事例が想起され、高く評価されるのかをあらかじめ予測できない実験状況を設定した。実験の目的は、Open-end な状況での類推の想起と評価に関する類似性を検討することであった。我々の実験において、被験者は実験者からベースを受け取らず、自身が日常で学習した事例を想起した。そこで得られた心理データを MAC/FAC モデルのアルゴリズムにしたがって分析した。つまり、心理データを分析する装置として計算機モデルを利用し、類推の想起と評価に対する表層的類似性 (CVector 値) と構造的類似性 (SES 値) の関与を検討した。

#### 3.1 材 料

[Gentner 93b] と同様、短いストーリーを実験の材料とした。だが、彼女らの実験とは異なり、ベースとなるストーリー (学習するストーリー) は用意せず、ターゲットとなるストーリー (想起の手がかり) のみを用意した。実験において、被験者は、一つのストーリーを呈示され、自身が日常で学習した事例を想起した。以降、本稿では実験材料としたストーリーを“ターゲットストーリー”と呼ぶ。

ターゲットストーリーのテキストは表層的な特徴と構造的な特徴を要因として操作された。表層特徴として「2匹の動物が登場するストーリー (A と呼ぶ)」と「2つの国が登場するストーリー (C と呼ぶ)」を用意した。構造特徴として、「平和から争いへストーリーが展開するプロット (PW と呼ぶ)」と「争いから平和へストーリーが展開するプロット (WP と呼ぶ)」を用意した。表層と構造の組み合わせで四種類のターゲットストーリー (A/PW, A/WP, C/PW, C/WP) が作られた。図2にターゲットストーリー (C/PW) の例を示した。

図3に示される命題はターゲットストーリーのテキストを変換したものである。各命題は2つの集合 (A, C) のいずれかに含まれる。2つの補集合  $[(A \cap \bar{C}), (\bar{A} \cap C)]$  に“属性”が含まれ、共通集合  $(A \cap C)$  に“1階の関係”が含まれる。1階の関係は二種類の矢印 (実線, 破線) で表現された“高次の関係”で結合される (PW, WP)。つまり、[Gentner 93b] と同様、全てのターゲットストーリーは1階の関係を共有し、属性と高次の関係が操作された。ターゲットストーリー間での述語タイプの共有を表1にまとめた。

上記の操作の妥当性を確かめるために、簡単な調査を行った。8名の被験者に4つのストーリーを示し、ストーリー間の類推としての良さを5段階 (1:低い-5:高い) で評定させた。結果、高次の関係が対応する組み合わせ (A/PW × C/PW, A/WP × C/WP) をその他の組み合わせ (A/PW × A/WP, A/PW × C/WP, A/WP × C/PW, C/PW × C/WP) よりも高く評定した被験者は8名中7名であり、構造的類似性の操作が、人による“類推としての良さ”の感覚と適合することが示された。

#### 3.2 被 験 者

被験者は大学生、大学院生33名であった。33名は呈示されるターゲットストーリーに応じて4群に分けられた。A/PWを示される群 (A/PW群と呼ぶ) に8名、A/WPを示される群 (A/WP群と呼ぶ) に9名、C/PWを示される群 (C/PW群と呼ぶ) に8名、C/WPを示される群 (C/WP群と呼ぶ) に8名が参加した。

#### 3.3 実験の手続き

実験の手続きは [Gentner 93b] とは異なり、被験者に想起すべきベースを学習させないものだった。被験者は個別、もしくは小グループ (2~5人) で実験に参加した。実験の手続きは以下の3フェーズに分かれた。

##### i. 検索フェーズ

はじめのフェーズで、被験者はターゲットストーリーの一つを呈示され、想起する事例を全て報告するように求められた。実験の目的を「文章から想起するエピソード」を検討するものと教示し、「呈示されたストーリーを読んで思い出したエピソードを全て書き出すように」と教示した。ここでの教示は [Gentner 93b] と極力、同じものとなるように気をつけた。被験者は20分間でターゲットストーリーから思い出される事例を全て記入用紙に書き出した。なお、記入用紙は、1行ごとに罫線で区切られた欄を含み、被験者は各行におさまる程度で各々のエピソードを簡潔に記述するようにと教示された。

##### ii. 評価フェーズ

検索フェーズが終わった後に事例の評価フェーズに移った。被験者は、自身が想起した事例と呈示されたターゲットストーリーとの“類推としての良さ”を5段階で評定した (1:悪い-5:良い)。

##### iii. 説明フェーズ

最後に、被験者は検索フェーズで想起した事例について、できる限り詳細にその内容を説明した。このフェーズで被験者は5cm × 15cmの記述欄を含む用紙を渡され、各欄を埋めるぐらいの分量で各事例の詳細な内容 (どのようなオブジェクトが登場するのか、どのような出来事が起きたのか、出来事間の因果関係) を記述するように教示された。このフェーズにおける記述を以下のコーディングに利用した。

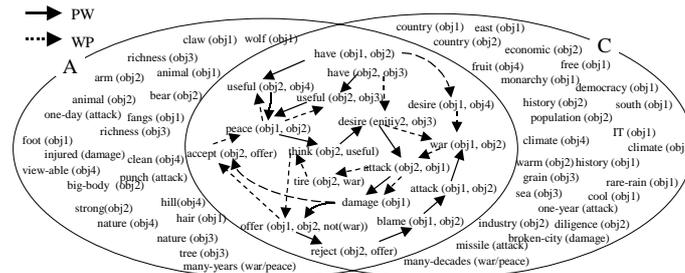


図 3 ターゲットストーリーに含まれる命題.

表 1 ターゲットストーリー間で共有する述語タイプ.

	A/PW	A/WP	C/PW	C/WP
A/PW	OA+FOR+HOR	OA+FOR	FOR+HOR	FOR
A/WP		OA+FOR+HOR	FOR	FOR+HOR
C/PW			OA+FOR+HOR	OA+FOR
C/WP				OA+FOR+HOR

Note. OA=object attributes; FOR=first-order relation; HOR=higher-order relation.

表 2 ターゲットストーリー間での類似性 (CVector 値/SES 値).

	A/PW	A/WP	C/PW	C/WP
A/PW	1.00/28.8	1.00/12.2	0.39/28.8	0.39/12.2
A/WP		1.00/27.9	0.39/12.2	0.39/27.9
C/PW			1.00/28.8	1.00/12.2
C/WP				1.00/27.9

なお、検索フェーズと説明フェーズを分けた理由は、フィルタリング (取捨選択) なしの事例想起を検討する必要があった一方で、コーディングのための詳細な情報が必要であったことによる。また、評価フェーズの後に説明フェーズを設定した理由は、事例の評価に説明の記述量 (被験者自身の努力量) が影響することを避けることにあった。逆に、評価フェーズを経ることで説明フェーズにおける記述の質と量が変化する可能性もあったが、この問題については、記述すべき説明の分量と内容を被験者に明示する努力を行った。なお、説明フェーズにおいて、検索フェーズで報告されていない事例が新たに報告された例はなかった。

#### 4. コーディング

心理実験により得られたデータは、(1) 被験者の想起した事例、(2) それに対する被験者自身の“類推としての良さ”の評定値であった。これら 2 つのデータはそれぞれ、初期の事例検索段階としての MAC 段階、抽出された事例の評価段階としての FAC 段階の出力に対応付けられる。それぞれの段階に關与する類似性を検討するために、以下のような最も直接的な方法でデータを分析した。

まず、被験者の想起した事例を命題形式に変換するために、ターゲットストーリーに含まれる全述語 (図 3) について、その定義を単語レベルで記述した述語リストを用意した。付録に全述語リストを示す。なお、述語を定義する際、MAC/FAC モデル (SME モデル) にデフォルトとして含まれている述語を優先的に用い、新しい述

語を恣意的に作ることは極力控えた。

想起事例のコーディングでは、まず、被験者の記述を述部に応じて分節化した。そして、その述部と述語リストを付き合わせ、適合する述語があるかどうかを判断した。述語リスト中に適合する述語があれば、適切な引数を補い、命題が作成された。被験者の記述と命題への変換の例を図 4 に示す。

それらの命題表現について、実験材料であるターゲットストーリーとの類似性を MAC/FAC モデルの二種類のアルゴリズムを通して算出した。CVector 値については、属性と 1 階の関係の頻度から単位ベクトルを作成し、ターゲットストーリーと想起事例間での内積を算出した。SES 値については公開されている SME (Version 2e [Falkenhainer 88]) を Allegro Common Lisp 6.2 上で実行して算出した\*3。SME2e にはいくつかのマッチングルールが存在するが、属性の対応を行わない Analogy rule を使用した\*4。ターゲットストーリーの命題表現 (ターゲット) と想起事例の命題表現 (ベース) を SME2e に入力し、ベース構造からターゲット構造への一貫して対応付けられる写像 (Global match) を算出した。

さらに、表 2 に、上記の手続きにしたがって算出したターゲットストーリー間の類似性を補足的に示した。表 2 に示されるように、属性を共有するターゲットストーリー間の CVector 値は属性を共有しないターゲットストーリー間の CVector 値に比べて高くなり、高次の関係を共有するターゲットストーリー間での SES 値は高次の関係を共有しないターゲットストーリー間の SES 値に比べて高くなった。このことはターゲットストーリー間での類似性の操作が MAC/FAC モデルのアルゴリズムに

\*3 Allegro Common Lisp 6.2 上で実行するために、関数の名前などを出力に影響のない範囲で書き換えた。

\*4 この手法は [Forbus 95] の採用したものの (Literal Similarity rule による SES 値の算出) と若干異なっている。しかし、“類推としての良さ”の評価を Analogy rule がよく説明することが示されており、本研究では類推の評価に関するアルゴリズムとして Analogy rule を想定した。

ドイツがユダヤ人を攻撃。ユダヤ人は迫害される。ユダヤ人も反撃をする。結局、他国が介入し、ナチスは攻撃され、鎮圧される。

```
(country german)
(country yudaya)
(country other)
((attack german yudaya) :name attack1)
((attack yudaya german) :name attack2)
((damage yudaya) :name damage1)
((damage german) :name damage2)
((cause attack1 damage1) :name cause1)
((cause damage1 attack2) :name cause2)
((attack other german) :name attack3)
((cause attack3 damage2) :name cause3)
((cause damage1 attack3) :name cause4)
```

図 4 被験者の想起した事例とその命題表現の例。

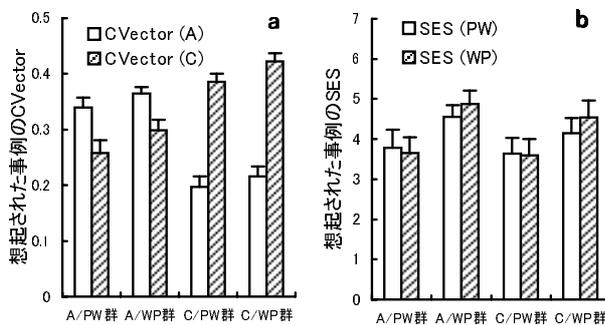


図 5 (a) 4 群における CVector 値の平均。(b) 4 群における SES 値の平均。Note. エラーバーは標準誤差を示す。

よって算出される類似性に即していることを示すものである。

なお、ターゲットストーリーと想起事例の間での CVector 値、SES 値を算出する際、比較のために、被験者に呈示したターゲットストーリーに対する類似性だけでなく、被験者には呈示しなかったターゲットストーリーに対する CVector 値、SES 値を算出した。

もし、[Forbus 95] による MAC/FAC モデルの理論的仮定が Open-end な状況でも成り立つのなら、被験者に呈示したターゲットストーリーに対する全想起事例の CVector 値の平均は被験者に示さなかったターゲットストーリーとの CVector 値の平均に比べて高くなるはずである。また、被験者に呈示したターゲットストーリーとの SES 値は被験者に示さなかったターゲットストーリーとの SES 値に比べ、“類推としての良さ”の評定値と強い関連をもつはずである。

## 5. 分析結果

以下、心理実験のデータを分析した結果を示す。まず、MAC 段階に關与する類似性を検討するために、想起された全事例に対して CVector 値と SES 値を算出した結果を示す。続いて、FAC 段階に關与する類似性を検討するために、“類推としての良さ”の各評定値ごとに CVector

値と SES 値を算出した結果を示す。

なお、被験者が想起した事例の総数は 266 だった [A/PW 群 51 (Mean 6.37, SD 1.86), A/WP 群 76 (Mean 8.37, SD 4.32), C/PW 群 75 (Mean 9.44, SD 4.78), C/WP 群 64 (Mean 8.37, SD 4.32)]。呈示されるターゲットストーリーの表層特徴、構造特徴による事例数の分布に有意な連関は認められず [ $\chi^2(3) = 6.15, ns.$ ]、 $2 \times 2$  [ターゲットストーリーの表層特徴 (between)  $\times$  ターゲットストーリーの構造特徴 (between)] 分散分析の結果、平均値の違いも有意とならなかった (表層特徴の主効果 [ $F(1, 29) = 0.09, ns.$ ]、構造特徴の主効果 [ $F(1, 29) = 1.05, ns.$ ]、交互作用 [ $F(1, 29) = 1.05, ns.$ ])。

### 5.1 MAC 段階に關与する類似性

MAC 段階 (初期の事例検索) に關与する類似性を検討するために、被験者が想起した各事例についてターゲットストーリーとの類似性を以下のように算出した。

- CVector (A): “表層特徴 A” (図 3 における集合 A) の CVector と “想起事例” の CVector との内積。
- CVector (C): “表層特徴 C” (図 3 における集合 C) の CVector と “想起事例” の CVector との内積。
- SES (PW): “構造特徴 PW” (図 3 における実線の矢印) と “想起事例” を SME モデルに入力して得られた SES 値。
- SES (WP): “構造特徴 WP” (図 3 における破線の矢印) と “想起事例” を SME モデルに入力して得られた SES 値。

[Forbus 95] による MAC 段階の仮定は初期の検索にはチープな表層的類似性 (CVector 値) が關与するというものであった。もし、この仮定が Open-end な状況でも成り立つのなら、次の「事例の想起に関する予測」が確かめられるはずである。

事例の想起に関する予測 A/PW 群, A/WP 群では CVector (A) が CVector (C) を上回る。C/PW 群, C/WP 群では CVector (C) が CVector (A) を上回る。しかし、SES (PW) と SES (WP) の差はどの群でもはっきりと認められない。

以下、この予測を念頭に、各群が想起した事例に対する各指標の値を検討する。

#### §1 MAC 段階における CVector 値の關与

図 5a に各群が想起した事例の CVector 値の平均を示した。図 5a から、A/PW 群, A/WP 群では CVector (A) が CVector (C) よりも高く、C/PW 群, C/WP 群では CVector (C) が CVector (A) よりも高くなったことが示される。つまり、予測と一致した傾向を示し、被験者の想起した事例は呈示されたターゲットストーリーと表層的によく類似したことが見てとれる。

このことの統計的な有意性を確かめるために、 $2 \times 2 \times 2$  [ターゲットストーリーの表層特徴 (between)  $\times$  ターゲットストーリーの構造特徴 (between)  $\times$  CVector 値の種

表 3 各指標が反映する述語タイプの対応/“ 類推としての良さ ”との相関.

	OA	FOR	HOR	1-1	r
CVector (presented)	yes	yes	no	no	0.23**
CVector (not presented)	no	yes	no	no	0.32**
SES (presented)	no	yes	yes	yes	0.44**
SES (not presented)	no	yes	no	yes	0.38**

Note. OA: object attributes, FOR: first-order relation, HOR: higher-order relation, 1-1: 一対一対応の制約, \*\*:  $p < .01$ .

類 (within)] 分散分析を実施した。結果, CVector 値の種類と表層特徴の交互作用が有意となった [ $F(1, 262) = 206.77, p < .05$ ]。単純主効果の検定から, 表層特徴 A を呈示された群では CVector (A) が CVector (C) を上回り [ $F(1, 262) = 30.26, p < .05$ ], 表層特徴 C を呈示された群では CVector (C) が CVector (A) を上回ったことが確認された [ $F(1, 262) = 220.07, p < .05$ ]。このように, 図 5a から見てとれる傾向は統計的に支持された。

§ 2 MAC 段階における SES 値の関与

図 5b に各群の想起事例の SES 平均値を示した。図 5b は予測と大まかに一致した傾向を示している。A/PW 群, C/PW 群では SES (PW) が SES (WP) よりも高く, A/WP 群, C/WP 群では SES (WP) が SES (PW) よりも高くなったことが見て取れるものの, その差は図 5a に比べ, はるかに曖昧である。

このことの統計的な有意性を確かめるために,  $2 \times 2 \times 2$  [ターゲットストーリーの表層特徴 (between)  $\times$  ターゲットストーリーの構造特徴 (between)  $\times$  SES 値の種類 (within)] 分散分析を実施した。その結果, ターゲットストーリーの構造特徴と SES 値の種類の交互作用が有意となった [ $F(1, 262) = 8.01, p < .05$ ]。単純主効果の検定から, 構造特徴 WP を呈示された群で SES (WP) が SES (PW) を上回ったことが確認された [ $F(1, 262) = 7.50, p < .05$ ]。しかし, 構造特徴 PW を呈示された群では SES (PW) と SES (WP) の差は有意とならなかった [ $F(1, 262) = 1.60, ns.$ ]。このように, SES 値を従属変数とした検定結果は CVector 値を従属変数とした検定結果に比べて, より曖昧なものとなった。

上記の結果と 5.1.1 節の結果を合わせて「事例の想起に関する予測」が確認される。つまり, Open-end な状況における類推の初期の検索において, チープな表層的類似性 (CVector 値: 属性と 1 階の関係の共有量) の関与が大きいということがわかった。

5.2 FAC 段階に關与する類似性

FAC 段階に關与する類似性を検討するために, “ 類推としての良さ ”の評定値と二種類の類似性 (CVector 値と SES 値) の関係を検討した。この分析では, ターゲット群を相殺し, 要因数を削減した\*5。具体的には, 図 5a,

b の各 8 条件を, 以下のように, 2 条件にそれぞれ圧縮した。

- *CVector (presented)*: 想起事例と被験者に呈示したターゲットストーリーとの表層的類似性を示す。A/PW 群, A/WP 群での CVector (A), C/PW 群, C/WP 群での CVector (C) を統合することで算出した。
- *CVector (not presented)*: 想起事例と被験者に呈示しなかったターゲットストーリーとの表層的類似性を示す。A/PW 群, A/WP 群での CVector (C), C/PW 群, C/WP 群での CVector (A) を統合することで算出した。
- *SES (presented)*: 想起事例と呈示したターゲットストーリーとの構造的類似性を表す。A/PW 群, C/PW 群での SES (PW), A/WP 群, C/WP 群での SES (WP) を統合することで算出した。
- *SES (not presented)*: 想起事例と被験者に呈示しなかったターゲットストーリーとの構造的類似性を表す。A/PW 群, C/PW 群での SES (WP), A/WP 群, C/WP 群での SES (PW) を統合することで算出した。

これら 4 つの指標が反映する述語の対応を整理したものが表 3 である。CVector (presented) が呈示されたターゲットストーリーとの属性の対応を反映し (表 3 の “ OA ”の列を参照), SES (presented) が呈示されたターゲットストーリーとの高次の関係の対応を反映する (表 3 の “ HOR ”の列を参照)。四種類のターゲットストーリーは 1 階の関係を共有するため (表 1 を参照), 全ての指標が呈示されたターゲットストーリーとの 1 階の関係の対応を反映する (表 3 の “ FOR ”の列を参照)。CVector (not presented) と SES (not presented) はともに 1 階の関係のみを推定する指標ということになるが, 一対一対応の制約に従うか否かが異なっている (表 3 の “ 1-1 ”の列を参照)。CVector 値はオブジェクト間の一対多対応を過剰に高く見積もる指標である。

[Forbus 95] による FAC 段階の仮定は, 類推の評価に詳細な構造的類似性の推定値 (SES 値) が關与することであった。そして, 構造的類似性とは, ベース構造からターゲット構造への一貫した写像と定義された。この定義を最も忠実に反映した指標は, 高次の関係を含んだ写像を計算する SES (presented) であることがわかる。そして, 二番目に定義を反映した指標は, 1 階の関係を一貫して対

\*5 評定値と被験者群間に有意な関連はなかった [ $\chi^2(12) = 11.04, ns.$ ]。なお, ターゲット群を相殺した場合, 評定値 1 の事例数 59, 評定値 2 の事例数 48, 評定値 3 の事例数 49, 評定値 4 の事例数 70, 評定値 5 の事例数 40 となった。

応付ける SES (not presented) であることがわかる。なお、構造的類似性の定義には属性の対応が含まれないため、CVector (presented) と CVector (not presented) は構造的類似性の観点からは区別されない。

よって、もし、[Forbus 95] による FAC 段階の仮定が Open-end な状況でも成り立つのなら、以下の「類推の評価に関する予測」が確かめられるはずである。

類推の評価に関する予測 評定値との関係の強さは次の順序に従う。[SES (presented) > SES (not presented) > CVector (presented) = CVector (not presented)]

この予測を念頭に、各指標について“類推としての良さ”の評定値との相関係数を計算した(表3の“*r*”の列)。結果、相関係数の大きさは上記の予測と大まかに一致した [SES (presented) > SES (not presented) > CVector (not presented) > CVector (presented)]。なお、相関係数の有意性を検定したところ、全ての指標において、1%水準で有意となった。これは、1階の関係の対応が評定値に反映したと解釈される。以下は、それぞれの指標と評定値との関係をより詳細に示し、予測を統計的に検定したものである。

### §1 FAC 段階における CVector 値の関与

図6aに“類推としての良さ”の評定値(1-5)ごとに想起事例の CVector 値の平均を示した。図6aから示される一つの傾向は、表3における相関係数を反映し、評定値の増加に伴って、CVector (presented), CVector (not presented) の両方の値が右上がりに上昇したことである。図6aにおいて注目すべきは、2つの折れ線グラフの傾きに顕著な違いがみられず、2つの指標の差が評定値の増減に影響を受けないように見えることである。このことは予測 [CVector (presented) = CVector (not presented)] と一致し、類推の評価において、CVector (presented) と CVector (not presented) は区別されないことを示している。

以上の傾向の統計的な有意性を確認するために、“類推としての良さ”の評定値 (between) と CVector 値の種類 (within) を要因とした  $5 \times 2$  分散分析を行った。その結果、CVector 値の種類と評定値間に交互作用は認められず [ $F(4, 261) = 1.59, ns.$ ]、CVector 値の種類 [ $F(1, 261) = 181.64, p < .05.$ ]、評定値 [ $F(4, 261) = 9.25, p < .05.$ ] の主効果が有意となった。CVector 値の種類と評定値間に交互作用が存在しなかったことは、“類推としての良さ”の評定に、CVector 値の種類は影響しなかったことを意味する。つまり、相関係数の値(表3)に見られた CVector (not presented) > CVector (presented) という順序は統計的に確かめられず、類推の評価において CVector (presented) と CVector (not presented) が区別されないことのみが示された。

なお、評定値の主効果については、LSD 法による多重比較から、評定値1に含まれる事例に比べて評定値2, 3,

4, 5に含まれる事例は平均値が大きいこと、評定値2, 3に含まれる事例に比べて評定値4に含まれる事例は平均値が大きいことが確かめられた ( $p < .05$ )。このことは、評定値の増加に伴って、CVector (presented), CVector (not presented) の両方の値が上昇した傾向にあることを示す。つまり、2つの指標が評定値とある程度関係を持つことが統計的に確かめられた。

### §2 FAC 段階における SES 値の関与

図6bに“類推としての良さ”の評定値ごとに、SES 値の平均を示した。図6bから見て取れる傾向は予測と一致するものである。まず、評定値の増加にしたがって、SES (presented), SES (not presented) の値が右上がりに上昇したことがわかる。その傾きは図6aよりも顕著であり、CVector (presented) よりも SES (not presented) は評定値と強い関係をもつという予測 [SES (not presented) > CVector (presented)] と一致する。また、同様に、評定値1から評定値4において2つの指標に差がなく、評定値5において SES (presented) が SES (not presented) を上回ったこともわかる。つまり、評定値4から評定値5にかけて値が上昇していない SES (not presented) に対して、SES (presented) は評定値4から評定値5にかけて上昇し、SES (presented) が SES (not presented) よりも評定値と強い関係をもつという予測 [SES (presented) > SES (not presented)] と一致した傾向になっている。

この傾向の統計的な有意性を確かめるために、“類推としての良さ”の評定値 (between) と SES 値の種類 (within) を要因とした  $5 \times 2$  分散分析を実施した。結果、評定値と SES 値の種類の交互作用が有意となり [ $F(4, 261) = 3.23, p < .05$ ]、評定値4と評定値5において SES (presented) が SES (not presented) を上回ったことが確認された [ $F(1, 261) = 18.67, p < .05$ ]。つまり、“類推としての良さ”を高く評価された事例における SES (presented) と SES (not presented) の差が示され、SES (presented) は SES (not presented) よりも評定値との強い関係を持つことが確かめられた。

また、SES (presented) [ $F(4, 261) = 13.17, p < .05$ ]、SES (not presented) [ $F(4, 261) = 11.32, p < .05$ ] の両方で単純主効果が有意となり、LSD 法による多重比較から、SES (presented) と SES (not presented) の両方で、評定値1と評定値3, 4, 5、評定値2と評定値4, 5、評定値3と評定値4, 5での差が有意となった ( $p < .05$ )。CVector 値での検定に引き続いて、評定値間での平均値の差が有意となったことは、SES 値が評定値の増加に伴って上昇したことを意味する。また、CVector 値での検定に比べ、有意となった評定値間の差が多くなったことは、CVector 値に比べて、SES 値は評定値の増減に敏感に影響を与えたことを意味する。このことから、SES 値は CVector 値に比べて、評定値との強い関係をもつという予測が統計的に確かめられた。

以上の結果と5.2.1節の結果を合わせて「類推の評価

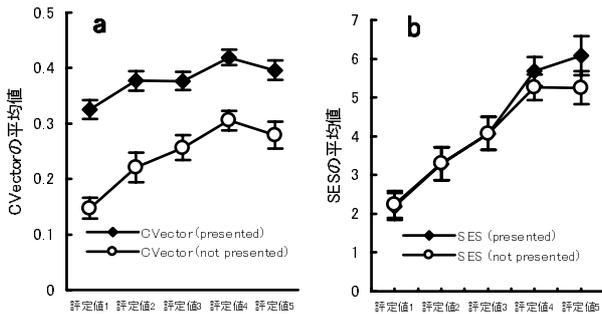


図 6 (a) “類推としての良さ”の評定値と CVector 値の平均値．  
(b) “類推としての良さ”の評定値と SES 値の平均． Note. エラーバーは標準誤差を表す．

に関する予測」が確認される．つまり，Open-end な状況における類推の評価に詳細な構造的類似性の推定値 (SES 値: ベース構造からターゲット構造への写像の大きさ) が関与するということがわかった．

## 6. 考 察

我々の実験において被験者は想起すべき事例を呈示されず，自身が日常で学習した事例を想起した．そして，そこで得られたデータに MAC/FAC モデルのアルゴリズムを適用した．結果，全想起事例に対するターゲット群間の差を CVector 値が SES 値よりもよく説明できたこと，“類推としての良さ”の評定値間の差を CVector 値よりも SES 値がよく説明できたこと，“類推としての良さ”を高く評定された事例ほど深い対応付けがなされたことが示された．これらの結果は，MAC/FAC モデルの理論的仮定 (MAC 段階における CVector 値の独占的な利用，FAC 段階における SES 値の独占的な利用というパラメータの値の設定) と一致する．つまり，類推の初期の段階 (ベースの想起) には表層的類似性が関与すること，類推の後期の段階 (類推の評価) には構造的類似性が関与することが示された．我々の実験は [Gentner 93b] とは異なり，被験者が保持する事例の推定ができない Open-end な状況であった．本研究は，[Gentner 93b] の知見を Open-end な状況で再現したものといえる．

本研究の類推研究に対する貢献は，本研究と同じように，Open-end な状況での類推を検討した [Blanchette 00] との対比によって，さらに明確になる．彼女らの実験で被験者はカナダ政府の財政赤字に関する類推を生成した．「赤字削減のために，福祉予算の削減を主張する立場」，もしくは「赤字削減をせずに，福祉の向上を主張する立場」のどちらかに立って，反対の立場を説得する類推をなるべく多く作ることが課題であった．被験者は自身の日常生活で学習した事例を用いて類推を生成し，実験の最後に，自身が生成した類推で最も良いもの一つを選択した．[Blanchette 00] の実施した実験と本研究の実験は，日常経験からの類推 (Open-end な状況での類推)

を検討したという点で類似している．

だが，[Blanchette 00] の実験結果は，本研究とは異なり，MAC/FAC モデルの仮定やそれを支持する [Gentner 93b] の結果を覆すものであった．実験の結果，ターゲットと表層的に類似した類推はほとんど作られず，表層的には類似しないもののターゲットと深い構造的対応をもつ類推が多数生成された．さらに，被験者に最も良いと選択された類推は選択されなかった類推よりも深い対応を持つものであった．つまり，類推の検索と評価の両方に構造的類似性が関与することが示され，表層的類似性が類推に果たす効果が否定された．この結果に基づいて，[Blanchette 00] は被験者自身が日常で学習した事例を検索する際には表層的類似性が影響力をもたないと主張した．日常で学習した事例は実験室で学習した事例に比べ，深く学習されており，構造的類似を手がかりとした検索が容易であると説明した．そして，MAC/FAC モデルの仮定やそれを支持する実証研究で得られた表層的類似性の効果は実験室に特異の現象であると主張した．

我々の実験結果は [Blanchette 00] の主張に再考を促すものである．本研究の実験結果と [Blanchette 00] の実験結果が異なった原因については，多くの可能性が考えられる．例えば，[Blanchette 00] の実験における“説得をする”という特殊な状況が表層的類似性の低い類推を想起させたのかもしれない．もしくは，財政赤字という被験者自身にとって既知のターゲットを示されたために，[Blanchette 00] の被験者は構造的類似性の高い類推を想起したのかもしれない (類推における熟達化の効果は数多くの研究によって示されている)．あるいは，[Blanchette 00] の実験において被験者が受けた「類推を生成するように」という教示が，表層的類似性の高い事例の報告を妨げたのかもしれない (同様の可能性は，[Dunbar 01] においても言及された)．これらから妥当な説明を，本稿において決定することは不可能である．いずれにせよ，本研究の結果から，表層的類似性と構造的類似性の区別が，実験室に特異な現象ではなく，人の類推のメカニズムを規定する最も重要な要因であることは示された．

さらに，我々は，[Blanchette 00] と比較したときに，本研究には明確な方法論的意義があると考えられる．[Blanchette 00] では，本研究のように計算機モデルを用いた分析は行われなかった．彼女らは，被験者の生成した類推をカテゴリ分けと要素の数え上げに基づいて分析した．表層的類似性に関する分析として「政治・経済」「病気・薬」「家事」といったテーマに関するカテゴリを設定し，各カテゴリの頻度を比較した．また，類推の深さに関しては，被験者の生成した類推とターゲット (財政赤字) との共通点を数え上げることで分析した．彼女らが数え上げた共通点は属性の共有と関係の共有を区別しないもので，構造的・一貫性に関する仮定も考慮されていなかった．つまり，[Blanchette 00] が検討した指標は，構造写像理論が仮定する類似性を厳密に具体化したものではなかった．それ

に対し、我々は検討の対象となっている理論を具体化した MAC/FAC モデルを直接的に適用することで、表層的類似性と構造的類似性の指標を算出した。我々が検討した指標は、[Blanchette 00] が検討した指標に比べて、理論に忠実なものである。計算機モデルの利用によって、[Gentner 83] が提唱した属性の対応、1 階の関係の対応、高次の関係の対応を区別でき、それに基づく類似性の定量的な検討が可能になった。計算機モデルを分析装置として利用することで、はじめて、構造写像理論から導かれる MAC/FAC モデルの理論的仮定を Open-end な状況で検討することに成功したと考える。

## 7. おわりに

本稿では、Open-end なデータを分析するツールとしての計算機モデルの利用を提案した。そして、提案した手法を類推の MAC/FAC モデルに適用し、Open-end な状況での類推の理論を検討することに成功した。なお、我々は、本研究の手法（分析装置としての利用）が旧来の手法（シミュレーション装置としての利用）に取って代わるとは考えていない。シミュレーションの実行は、認知に関する新しい仮説を演繹的に導くという意味で重要である。本研究の手法は事前の知識推定が困難な Open-end な状況での認知を検討することに利点をもち、旧来の手法を補完するものである。この考えは [Miwa 99] の Behavior oriented approach と Model oriented approach の関係に関する議論を受け継いでいる。Behavior oriented approach とは心理データからの知識・パラメータの値の設定を意味し、Model oriented approach とは理論からの知識・パラメータの値の設定を意味する。本研究の手法は従来の Behavior oriented approach に立つシミュレーション研究から派生するものである。[Miwa 99] は認知科学の発展において、2 つのアプローチの相補的な使用が望ましいと論じた。

なお、本研究の対象とした分野は限定されており、提案した手法が認知研究一般に対して有用であることは示していない。だが、本稿で示した手法は幅広い認知研究に対して意義があると考えられる。Open-end な状況で得られた心理データを分析することで現実的な状況における理論の適応を検討することが可能になり、モデルを介した量的な指標の算出により心理データの詳細な分析が可能になる。計算機モデルは認知理論の具体化であり、計算機モデルを利用した心理データの分析は、データと理論的構成概念を強固に結合する効果がある。本研究で対象としたような複雑で抽象的な理論的構成概念（表層的類似性と構造的類似性）を計算機モデルなしに具体化することは困難である。認知研究にとって最も重要なことは理論とデータとの結合であり、理論を具体化した計算機モデルを利用することで、理論とデータとの結合が強固になると考える。

## 謝 辞

本論文の執筆にあたり、査読者の方々には非常に有益なコメントを頂きました。ここに感謝の意を表します。

## ◇ 参 考 文 献 ◇

- [Anderson 03] Anderson, J. and Lebiere, C.: The Newell Test for a theory of cognition, *Behavioral and Brain Sciences*, Vol. 26, pp. 587–601 (2003)
- [Blanchette 00] Blanchette, I. and Dunbar, K.: How analogies are generated: The role of structural and superficial similarity, *Memory & Cognition*, Vol. 28, pp. 108–124 (2000)
- [Dunbar 01] Dunbar, K. and Blanchette, I.: The in vivo/in vitro approach to cognition: the case of analogy, *Trends in cognitive science*, Vol. 5, pp. 334–339 (2001)
- [Falkenhainer 88] Falkenhainer, B.: The SME user's manual (SME Version 2E), *Technical report UIUCDCS-R-88-1421* (1988)
- [Falkenhainer 89] Falkenhainer, B., Forbus, K., and Gentner, D.: The Structure-Mapping Engine: Algorithm and Example, *Artificial Intelligence*, Vol. 41, pp. 1–63 (1989)
- [Forbus 95] Forbus, K., Gentner, D., and Law, K.: MAC/FAC: A model of similarity-based retrieval, *Cognitive Science*, Vol. 19, pp. 141–205 (1995)
- [Forbus 01] Forbus, K.: Exploring Analogy in the Large, in Gentner, D., Holyoak, K. J., and Kokinov, B. N. eds., *Analogical Mind: Perspectives from cognitive science*, chapter 2, pp. 23–58, Cambridge, MA: MIT Press (2001)
- [Gentner 83] Gentner, D.: A theoretical framework for analogy, *Cognitive Science*, Vol. 7, pp. 155–170 (1983)
- [Gentner 93a] Gentner, D. and Jeziorski, M.: The shift from metaphor to analogy in Western Science, in Ortony, A. ed., *Metaphor and thought (2nd ed.)*, pp. 447–480, New York, NY: Cambridge University Press (1993)
- [Gentner 93b] Gentner, D., Rattermann, M., and Forbus, K. D.: The role of similarity in transfer: Separating retrievability for inferential soundness, *Cognitive Psychology*, Vol. 25, pp. 524–575 (1993)
- [Gick 80] Gick, M. L. and Holyoak, K. J.: Analogical Problem Solving, *Cognitive Psychology*, Vol. 12, pp. 306–355 (1980)
- [Markman 93] Markman, A. B. and Gentner, D.: Structural Alignment during Similarity Comparisons, *Cognitive Psychology*, Vol. 25, pp. 431–467 (1993)
- [Markman 97] Markman, A. B.: Constraints on analogical inference, *Cognitive Science*, Vol. 21, pp. 373–418 (1997)
- [Markman 01] Markman, A. B. and Moreau, C. P.: Analogy and analogical comparison in choice, in Gentner, D., Holyoak, K. J., and Kokinov, B. N. eds., *Analogical Mind: Perspectives from cognitive science*, chapter 11, pp. 363–399, Cambridge, MA: MIT Press (2001)
- [Miwa 99] Miwa, K.: Deductive and Inductive way of investigation on human problem solving, *人工知能学会誌*, Vol. 14, No. 6, pp. 1165–1176 (1999)
- [Ritter 04] Ritter, F.: Choosing and getting started with a cognitive architecture to test and use human-machine interfaces, *MMI-Interaktiv*, Vol. 7, pp. 17–37 (2004)

〔担当委員：庄司 裕子〕

2004 年 12 月 6 日 受理

◇ 付 録 ◇

A. 属性の定義

- after-days: ある出来事がそれ以前の出来事の数日後に起きた場合に使用.
- after-months: ある出来事がそれ以前の出来事の数ヶ月後に起きた場合に使用.
- many-year: 関係が数年間に渡って続いていると言及された場合に使用.
- many-decade: 関係が何十年にわたって続いていると言及された場合に使用.
- oneday: ある出来事が起きた日が言及されている場合に使用.
- oneyear: ある出来事が起きた年が言及されている場合に使用.
- animal: 動物 (人を除く有機体) を表す単語が言及された場合に使用 (狼, 熊, 鷲, ミトコンドリア, ウィルス...).
- bear: 熊という単語が現われた場合に使用.
- wolf: 狼という単語が現われた場合に使用.
- country: 国名 (日本・ドイツ・アメリカなど) が言及された場合に使用.
- democracy: 民主制 (民主主義/民主国) という単語が現われた場合に使用.
- monarchy: 君主制 (君主国) という単語が現われた場合に使用.
- arm: 腕という単語が現われた場合に使用.
- big-body: 身体が大きいと推測される記述がある場合に使用.
- hair: 毛・髪という単語が現われた場合に使用.
- claw: 爪という単語が現われた場合に使用.
- strong: 肉体が強いと推測される場合に使用.
- foot: 足という単語が現われた場合に使用.
- fangs: 牙・歯という単語が現われた場合に使用.
- diligence: 勤勉という単語が現われた場合に使用.
- free: 自由という単語が現われた場合に使用. 自由でないことが推測される記述が表れた場合は not (free).
- history: 歴史・伝統という単語が現われた場合に使用.
- population: 人口という単語が現われた場合に使用.
- industry: 工業という単語が現われた場合に使用.
- IT: 情報産業という単語が現われた場合に使用.
- economic: 経済・市場という単語が現われた場合に使用.
- nature: 自然という単語が現われた場合に使用.
- clean: 空気がうまい・きれい・澄んでいると言及された場合に使用.
- broad: 広いという単語が現われた場合に使用.
- richness: 豊かという単語が現われた場合に使用.
- hill: 山や丘という単語が現われた場合に使用.
- tree: 森・林・木という単語が現われた場合に使用.
- view-able: 見晴らしが良いという記述が現われた場合に使用.
- east: 東という単語が出現した場合に使用.
- south: 南という単語が出現した場合に使用.
- cool: 土地が涼しい, 寒いと言及があった場合に使用.
- warm: 温暖, 暖かいと言及があった場合に使用.
- sea: 海, プール, 泳ぐなどという単語があった場合に使用.
- fruit: 果物に関する言及があった場合に使用.
- grain: 穀物に関する言及があった場合に使用.
- injured: Entity(動物・人) が骨折, 怪我, 病気になった場合に使用.
- broken-city: Entity(国) の都市が破壊された場合に使用.
- missile: ミサイル (大量殺戮が可能な兵器) という名詞が言及された場合に使用.
- punch: 殴る・蹴る・投げる・飛びかかるなど肉体的攻撃が言及されている場合に使用. 武器を使った攻撃 [剣, 銃, 魔法] では使用しない.

B. 1 階の関係の定義

- peace: 友好, 仲良く, 協力, 手を組む, 同盟, 平和などの記述が現われた場合, 2 者間の関係がうまくいっていると推測される場合に使用. 引数には entity が言及されていれば, それ

をいれ, 言及されていない場合は entity を定義している.

- war: 戦争, ケンカ, 争い, 闘争, 戦いなどの単語が現われた場合は使用. 引数には entity が言及されていれば, それをいれ, 言及されていない場合は entity を定義している.
- attack: 攻撃, 殴る, ミサイル発射, 侵略, 批判, イジメなど, 一方が他方に被害を被らせる記述があった場合に使用.
- damage: Entity がなんらかの被害 (敗北, 絶滅, 死亡, 迫害) をこうむった場合に使用. 戦争やケンカなどで負けた場合にも使用. 勝ったという記述が現われたら, 負けた側がダメージ.
- have: 第 1 引数がかか (土地, 利益, もの, 人) を持っている状態が推測される場合に使用.
- useful: 自由に使用可能な状態が言及された場合, 戦争や平和の結果, 何かを手に入れた場合に使用. 第 2 引数には土地, 利益, もの, 人などがはいる. 記述中に適切なものがなければ, 適当な entity を定義している.
- desire: 望んでいる状態 (欲する, 狙う) が言及された場合に使用. 第 2 引数には土地, 利益, もの, 人などがはいる. 記述中に適切なものがなければ適当な entity を定義している.
- think: 考えた, 思った, 予測したなど心的過程を表す述語が明示された場合に使用.
- tire: 疲れた, 嫌になったなどの言及があった場合に使用.
- blame: 第 1 引数が第 2 引数に対して負の感情 (恨む, 憎む) を持つ場合に使用.
- offer: 第 1 引数が第 2 引数になんらかのコミュニケーション (謝る・提案する) をとった場合に使用. 第 3 引数にはコミュニケーションの内容を入れる. 内容を命題で表現可能な場合は命題で表現. 表現できなければ, entity をいれる.
- accept: 第 1 引数が offer を受け入れたと推測される場合には accept.
- reject: 第 1 引数が offer を受け入れなかったと推測される場合は reject. offer と accept/reject は cause で結合する.

C. 高次関係の定義

- and: cause の第 1 引数として使う. 2 つの原因が複合して何らかの結果を導いたときに使用. 第 2 引数には使わない.
- not: 否定を表す. offer の第 3 引数として使用することが多い.
- cause: 因果関係が推測できる場合は cause (原因, 結果). 時間的な前後関係を推測できる場合は, cause (前, 後).

著 者 紹 介

森田 純哉 (学生会員)



2002 年名古屋大学人間情報学研究所博士前期課程修了. 同年, 同研究所博士後期課程に入学し, 現在に至る. 基礎理論と密接に繋がった応用研究を志向し, 現実場面での類推利用, 医用画像診断における診断プロセスなどの研究に従事する. Cognitive Science Society, 日本認知科学会の各学生会員.

三輪 和久 (正会員)



1984 年名古屋大学工学部卒業. 1989 年同大学大学院工学研究科博士課程修了 (情報工学専攻). 工学博士. 1989 年同大学情報処理教育センター助手, 1993 年同大学大学院人間情報学研究所助教授を経て, 2004 年より名古屋大学大学院情報科学研究科メディア科学専攻教授. 1991 年から 1992 年, 米国 Carnegie Mellon University, Dept. of Psychology, visiting assistant professor. 認知科学, 人工知能, 教育学の研究に従事. とりわけ, 発見, 創造, 洞察, 協同など, 人間の高次思考過程に興味がある.