

# 帰納的推論の計算モデルが明らかにする人格と状況の相互作用

坂本 佳陽

(sakamoto.k.ad@m.titech.ac.jp)

日本学術振興会；東京工業大学

中川 正宣

(nakagawa@nm.hum.titech.ac.jp)

東京工業大学

## 概要

Sakamoto & Nakagawa (2007; 2008)は、正事例と負事例を含む帰納的推論の計算モデルを構築、発展させてきた。モデルは帰納的推論における結論のもっともらしさの評定を2つの類似性関数、すなわち正事例と結論との類似性関数と負事例と結論との類似性関数に基づき説明する。そしてそれらの類似性関数のパラメータを用いて、モデルが出力するもっともらしさ評定における2つの類似性の「強度バランス」が表現される。さらに、この強度バランスの違いに基づき、異なる状況によって帰納的推論の評定が異なるという現象が説明されている(Sakamoto & Nakagawa, 2007; 2008)。本研究は、モデル上で表現されるその強度バランスが、帰納的推論評定における状況と評定者の人格との相互作用をも説明しようという更なる可能性を追求する。今回は特に、心理実験結果のモデル表現に基づき、神経症傾向の強い評定者は状況による影響を受けないこと、外向性傾向の強い評定者は状況に関わらず負事例と結論との類似性を重視することが明らかになった。

**Keywords:** 帰納的推論; 計算モデル; パーソナリティ; 状況による影響; コーパス統計解析。

## はじめに

本研究は、次のような空白の述語に関する帰納的推論を取り扱う (e.g., Rips, 1975; Osherson, Smith, Wilkie, Lopez, & Shafir, 1990)。

人物 A はワインが好きである。  
人物 A はシャンパンが好きである。

ここで、前提 (線の上の文) に基づく結論 (線の下) のもっともらしさは、主に空白の述語 (人物 A は~が好きである) の対象 (ワイン、シャンパン) によって決定される。ここにおける空白の述語とは、その外延があきらかでない述語のことである。例えば上記の例では、「ワイン」という事例が与えられないと、人物 A がどんなものが好きかはわからないので (述語「人物 A は~が好きである」のメンバーが特定されない)、空白の述語であるということが出来る。本研究では特に、空白の述語に関する帰納的推論の中で、次のように正事例前提と負事例前提を含むケースを取り扱う。

人物 A はワインが好きである。  
人物 A はビールが好きではない。  
人物 A はシャンパンが好きである。

ここで2番目の前提は、空白の述語は否定的表現をとるため、1番目の前提が正事例前提であるのに対し、負事例前提と呼ぶことにする。このような帰納的推論では、結論の対象が正事例の対象と類似しているときにもっともらしさ評定が高くなり、負事例と類似しているときにもっともらしさ評定が低くなる。しかし、結論の対象が正事例の対象とも負事例の対象とも類似しているときはどうなるのだろうか？

正事例とも負事例とも結論が類似している場合の帰納的推論評定は、評定における (あるいはその評定に基づく行動における) 状況の影響を受けるのではないだろうか。例えば先ほどの帰納的推論の例を再び取り上げ、ワインが好きで、ビールが好きでないことがわかっている人物 A に関し、シャンパンをプレゼントした際の反応 (人物 A が本当にシャンパンが好きで喜ぶか、実は好きではなく嫌がるか) を「推論」することを考える。このような状況では、結論のもっともらしさ (人物 A がシャンパンが好きである) は、人物 A が例えば評定者の近い友人であるときと、怒りっぽい上司であるときで異なるのではないだろうか。すなわち、近い友人と怒りっぽい上司では、推論が不適切であったときに望ましくない結果 (相手を怒らせて評定者が不利な状況に置かれるなど) が生じる可能性が異なるので、推論の評定も異なるのではないかということである。このような視点のもと、Sakamoto & Nakagawa (2007; 2008) では、帰納的推論の評定が状況に依存的事であること、それが帰納的推論の計算モデルのパラメータで説明できることを示してきた。

しかし一方で、望ましくない結果が生じうる、いわばリスク的な状況というのは、個人によって認識のされ方が異なるだろう。例えば、保守的な人格の持ち主と挑戦的な人格の持ち主では、状況依存の帰納的推論評定は異なるのではないだろうか。本研究は帰納的推論評定の状況と評定者のパーソナリティとの関係を検証することを目的とする。

本研究の概要は次の通りである。まず、Sakamoto & Nakagawa (2007; 2008) が構築、発展してきたモデルを説明する。次に状況依存の帰納的推論に関する実験について述べる。また、モデルのパラメータを実験データから推定した結果によって、実験によって示された状況依存の帰納的推論は、正事例-結論の類似性と負事例-結論の類似性と強度バランスによって説明されることを示す。さらに、被験者の個人パラメータの推定結果により、状況とパーソナリティにより帰納

的推論評定には相互作用も含むバリエーションがあることを示す。最後に、それらのバリエーションについての解釈について議論する。

## モデル

ここでは、Sakamoto & Nakagawa(2007; 2008) が構築、発展させてきた帰納的推論のカーネル関数モデルについて述べる。構造としては、このモデルは一種の回帰モデル<sup>1</sup>である。従属変数（モデル出力）は帰納的推論の評定値で、説明変数は 2 つの類似性関数である。ひとつは正事例—結論の類似性を計算し、もう一つは負事例—結論の類似性を計算する。これらの類似性はコーパスの統計解析結果から構築される意味空間上の距離に基づく。モデルのパラメータ（回帰係数）は帰納的推論における状況の違いを説明することができる。

**モデルにおける意味空間の構築** 意味空間を構築するため、日本語コーパスのソフトクラスタリング結果を利用する。この手法では、名詞が特徴強度に基づいてクラスタリングされる。このとき、係り受け頻度が名詞と特徴の強度を反映すると仮定し、その名詞の各クラスターへの帰属確率が名詞と動詞の述語—目的格関係、主格—述語関係などの係り受け頻度から推定される。この手法の構造はPereiraのモデル(Pereira, Tishby, & Lee, 1993)やPLSI(Hofmann, 1999)などに代表される自然言語処理における手法と類似している(この手法の詳細はSakamoto and Nakagawa (2007)を参照)。この分析の結果、600 クラスターに関する 18,142 名詞の帰属確率 $P(\text{クラスター}|\text{名詞})$ が推定された。本研究では、このクラスター $C$ が名詞の上位概念カテゴリーであり、帰属確率がそのカテゴリーの典型性を反映すると仮定する。あるカテゴリーがある名詞を与えたときに高い条件付き確率を示すなら、その名詞が指示する対象はそのカテゴリーが示す特徴を帯びていると考えられる。これをふまえ、各カテゴリー $C$ を次元として考えることで、対象がコーパス解析から構築される意味空間上で表現される<sup>2</sup>。

**モデル構築** モデルの出力は帰納的推論の評定値、すなわち、対象  $N_1^+, \dots, N_n^+$  を含む正事例と対象  $N_1^-, \dots, N_n^-$  を含む負事例に基づく対象  $N^c$  を含む結

論のもっともらしさ  $v(N^c)$  である。  $v(N^c)$  は次のように表現される。

$$v(N^c) = a\text{SIM}_+(N^c) + b\text{SIM}_-(N^c), \quad (1)$$

$$\text{ここで、} \text{SIM}_+(N^c) = \sum_i^{n^+} e^{-\beta d_{ci}^+}, \quad (2)$$

$$\text{SIM}_-(N^c) = \sum_j^{n^-} e^{-\beta d_{cj}^-}, \quad (3)$$

$$d_{ci}^+ = \sum_k^m (P(C_k | N^c) - P(C_k | N_i^+))^2, \quad (4)$$

$$d_{cj}^- = \sum_k^m (P(C_k | N^c) - P(C_k | N_j^-))^2. \quad (5)$$

$d_{ci}^+$  と  $d_{cj}^-$  はカテゴリー特徴 ( $C_k$ ) に基づく対象間の距離の 2 乗である。 $d_{ci}^+$  は結論の対象  $N^c$  と正事例前提の対象  $N_i^+$  との距離の 2 乗で、 $d_{cj}^-$  は負事例前提の対象  $N_j^-$  と結論の対象  $N^c$  との距離の 2 乗である。ここではカテゴリーの数、すなわち意味空間の次元の数は  $m$  は 20 とした。すなわち、関連するカテゴリーのみが推論で利用されると仮定して、推定された 600 カテゴリーから、正事例、負事例前提と関連の強い 20 カテゴリーを選出した。これらの距離関数は、パラメータ  $\beta$  を導入して（本研究では  $\beta = 1$  とする）非線形exp関数を適用し、 $\text{SIM}_+(N^c)$  と  $\text{SIM}_-(N^c)$  のようなガウシアンカーネル関数<sup>3</sup>を構成する。このガウシアンカーネル関数は、非線形類似性関数であると解釈できる。 $\text{SIM}_+(N^c)$  が結論の対象  $N^c$  と正事例前提  $N_1^+, \dots, N_n^+$  との類似性関数で、 $\text{SIM}_-(N^c)$  が結論の対象と負事例前提  $N_1^-, \dots, N_n^-$  との類似性関数であるとする。さらに、 $a$  と  $b$  は類似性関数の係数パラメータである。パラメータ  $a$  は正事例—結論の類似性関数に関連しているので正の値( $a > 0$ )をとるはずであり、パラメータ  $b$  は負事例—結論の類似性関数に関連しているので負の値( $b < 0$ )をとるはずである。これらのパラメータは結論  $N^c$  の評定値  $v(N^c) = 0$  となる超平面を定義する。この超平面は正事例の領域と負事例の領域の境界として見ることもできる。従って、パラメータの割合の絶対値  $|b/a|$  は、結論の評定における正事例の類似性と負事例の類似性との強度バランスを表現している。図 1 は、


<sup>1</sup> この構造はカーネル法を用いたサポートベクトルマシンと同型である (Vapnik, 1992)。

<sup>2</sup> 潜在意味分析(Latent Semantic Analysis, LSA)を用いてもコーパスの係り受け頻度から意味空間を構築することは可能である(Deerwester et al., 1990)。ただし、LSAが特異値分解に基づいて意味空間を構築するのに対し、本研究の手法では確率的制約条件の下での最尤法に基づいたクラスター推定から意味空間を構築しているという違いがある。

<sup>3</sup> カーネル関数がサポートベクトルマシンに適用されるとき、線形モデルにおいて非線形分類問題が解決可能になる。これは、カーネル関数が線形分類、または線形回帰が可能な空間に入力データを写像するからである。(Vapnik, 1992)

次のような同じ帰納的推論における異なる強度バランスによる処理を表している。

人物 A はワインが好きである。  
 人物 A はビールが好きではない。  
 人物 A はシャンパンが好きである。



従って、結論が意味空間における曲線（超平面）から見て「ワイン」側（正事例の領域）にある場合、もっともらしさの評定は 0 より大きくなり（正の値）、

図 1. 異なる強度バランス

1セット目: キシヘキ語の単語“バミソヤ”の意味について

わかっている例文	
「"ジャンボ機"はバミソヤである。」	「"バス"はバミソヤではない。」
「"フェリー"はバミソヤである。」	「"電車"はバミソヤではない。」
「"小舟"はバミソヤである。」	「"刑務所"はバミソヤではない。」

それでは、クイズです。  
 “バミソヤ”について上記の例文がわかっているとき、下記の例文はどのくらい適切か、該当するボタンをクリックしてください。

「"トレーラー"はバミソヤである。」						
<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
まさに適切である	かなり適切である	どちらかといえば適切である	どちらでもない	どちらかといえば不適切である	かなり不適切である	まったく不適切である

配点						
正解から3段階以上過大評価	正解から2段階過大評価	正解から1段階過大評価	正解と一致	正解から1段階過小評価	正解から2段階過小評価	正解から3段階以上過小評価
-100点	-65点	-35点	100点	65点	35点	0点

図 2. Over条件における課題の例

「ビール」側(負事例の領域)にある場合、もっともらしさの評定は 0 より小さくなる（負の値）。図 1 の (1) では、正事例の領域が小さく結論「シャンパン」はこの領域に含まれないので、評定が低くなる（負の値になる）。一方図 1 の (2) では、正事例の領域が大きく同じ結論「シャンパン」の評定が大きくなる（正の値になる）。従って、モデルで表現される「強度バランス」は帰納的推論における異なる状況の効果を説明できる。

実験

ここでは Sakamoto and Nakagawa (2008)で実施された実験について述べる。この実験では帰納的推論の評定が状況によって異なることを示している。

実験の方法

課題 課題は帰納的推論の 7 段階評定（かなりあり得る～全くあり得ない）であった（図 2）。通常の帰納的推論課題と異なり、各評定は架空の正解評定からの差に応じて得点化される。被験者は正解評定を当てるこ

とで新しい言語（バミソヤなどの無意味語）の意味を学習する能力が測定されると説明された。従って被験者にとってこの課題は自分の言語能力が低く評価されるというある種のリスクを伴うことになる。正解評定と一致する評定の場合、満点が加算された。架空の正解評定はこのような状況が伴わない状況非依存の実験データを参考に決定された。ここで、ある種のリスクの生じやすさが異なる 2 つの実験条件が計画された。過大評価リスク条件（Over）では、正解評定より高く評定するほど大きく減点された。一方過小評価リスク条件（Under）では正解評定より低く評定するほど大きく減点された。各条件における配点を表 1 に示す。

課題の題材 4 種類の意味的領域<sup>4</sup>から対象を選択した 4 セットの帰納的推論を使用した（表 2）。各セットはそれぞれ共通の 3 つの正事例、3 つの負事例に対して 8 つの結論についての評定から構成された。正事例前

<sup>4</sup> 各意味的領域について、正事例対象をモデルの意味空間上における特定の領域から選択し、負事例対象を別の領域から選択し、結論対象をその両方の領域から選択した。

表 1. 各実験条件における配点

	3段階以上 過大評価	2段階 過大評価	1段階 過大評価	正解と一致	1段階 過小評価	2段階 過小評価	3段階以上 過小評価
<b>UNDER</b>	0点	+35点	+65点	+100点	-35点	-65点	-100点
<b>OVER</b>	-100点	-65点	-35点	+100点	+65点	+35点	0点

提、結論の対象(飛行機)はそれぞれ共通の無意味語に関する空白の述語(～はバミソヤである)と関連付けられ(例:飛行機はバミソヤである)、負事例前提の場合は空白の述語の否定的表現(～はバミソヤではない)と関連付けられた(例:トレーラーはバミソヤではない)。

**被験者** 被験者は大学生 118 人で、58 人が Over 条件に、60 人が Under 条件に割り当てられた。

**手続き** 実験の全手続きは、Internet Explorer 6.0 で動作する WEB アプリケーションによって制御された。被験者はこの手続きに従い、一斉に実験を行った。手続きは 6 つの段階から構成されていた。段階 1 は実験の教示、段階 2 は 4 つの課題セットのうちの一つを用いて、練習評定セッションとして評定ごとに得点のフィードバックが与えられた。段階 3～5 は残りの課題 3 セットについて得点フィードバックのない評定セッション(ただし、各セッションの最後にそのときの総合点のフィードバックはあり)、段階 6 は総合得点と実験グループ内のランキングの提示であった。全手続きが終了したのちに、被験者に実験の本当の目的が説明された。

### 実験結果

フィードバックのない課題 3 セットの 7 段階評定について、1～7 の値に数値化し、実験条件ごとに分析した。3 セット 24 課題の評点平均は Under 条件で 3.783 ( $SD = 1.248$ )、Over 条件で 3.578 ( $SD = 1.210$ )であった。課題について対応をとり、 $t$  検定を行ったところ有意な差が確認された( $p < 0.01$ )。

以上の結果は被験者の評定がリスク的な状況の影響を受けることを示唆している。すなわち、Over 条件では、減点が生じる可能性が高い過大評価を避けようとすることにより、評定が低くなり、Under 条件では原点が生じやすくなる過小評価を避けようとして評定が高くなったのではないかと解釈できる。

### モデルシミュレーション

#### モデルにおける仮定の妥当性

まず、モデルにおける仮定の妥当性を検証する。モデルは帰納的推論の評定が 2 つの類似性、すなわち正事例—結論の類似性と負事例—結論の類似性に

よって説明されると仮定している。さらに、これらの類似性はカテゴリにより計算され、そのカテゴリはコーパスの統計解析によって推定されると仮定している。これらの仮定の妥当性について、重回帰分析の視点で評価する。もし仮定が妥当でなければ、モデルのフィットが有意でなかったり、推定された回帰係数が解釈できなかったり(パラメータ  $a$  が負、パラメータ  $b$  が正など)するだろう。ここでは、被験者個人ごとに回帰分析を行う。被験者ごとにパラメータ(回帰係数)  $a$  と  $b$  が、実験評定値(24 評定)によって最小二乗法で推定され、 $F$  比に基づきモデルのフィッティングが評価された。ここでは 7 段階評定を -3 ~ 3 に数値化して分析した。その結果、被験者 118 人中 107 人の分析結果が有意なフィッティングを示し( $F$  比による検定、 $p < 0.05$ )、かつ推定された回帰係数は妥当な値を示した(117 人分の回帰係数  $a$  が全て正、回帰係数  $b$  が全て負)。このことから、モデルの仮定は妥当であ

表 2. 課題セットの例

<対象> はバミソヤである。	
正事例の対象	ジャンボ機
	フェリー
	小舟
負事例の対象	バス
	電車
	刑務所
結論の対象	乗用車
	ブイ
	飛行機
	水族館
	区役所
	トレーラー
	タクシー
	漁船

ることが検証された。

### モデルで表現される状況の効果

実験では、被験者の評定がリスク的な状況の影響を受けることが示された。ここでは、この結果がモデルの強度バランスの違いによるものかどうかを検証する。すなわち **Over** 条件では、負事例の類似性をより重視し ( $|b/a|$ が大)、**Under** 条件ではあまり重視しない ( $|b/a|$ が小) ことが条件における差となったのどうかを検証する。ここでは、前項で推定された有意な  $F$  比を示す個人回帰係数を条件ごとに分類して比較した。その結果、条件ごとの強度バランスの平均は、**Over** 条件で 1.164 ( $SD=0.087$ )、**Under** 条件で 1.104 ( $SD=0.131$ ) となり、対応のない  $t$  検定で有意な差が確認され、仮説が示唆された ( $p < 0.01$ )。

しかし、実験結果は他の解釈も可能である。例えば負事例の重視とは関係なく、24 評定全てに対して一律に評定値を高くしたり、低くしたりしても同様の結果を得ることができる。モデルに即して考えると、図 1 における正事例と負事例の境界における評定値を調節することによっても条件間の差は出てしまう。この代替仮説を棄却するため、次のような統制モデルを提案した。

$$v(N^c) = aSIM_+(N^c) + bSIM_-(N^c) + c, \quad (6)$$

この統制モデルは、オリジナルモデル (式 1) に切片パラメータ  $c$  を加え、オリジナルモデルでは 0 と仮定していた正事例と負事例の境界上の評定値を検討できるようにしたものである。この統制モデルに関し、前項と同様の回帰分析を行い、有意な  $F$  比でスクリーニングし (118 人中 102 人のデータが  $p < 0.05$  で有意)、条件間で回帰係数を比較した。その結果回帰係数  $c$  の平均について、**Over** 条件で 1.064 ( $SD=1.681$ )、**Under** 条件で 0.835 ( $SD=1.520$ ) となり、条件間で有意な差は確認されなかった。これは帰納的推論の状況効果が評定の一律な調節によるものではなく、正事例の類似性と負事例の類似性の強度バランスの違いによるものであることを支持している。この解釈の検証は実験のみでは明らかにならず、モデルシミュレーションによって初めて明らかになることを強調したい。

### 状況とパーソナリティの関係

前項において強度バランス  $|b/a|$  が帰納的推論における状況効果を説明できることを示したが、各実験条件における状況の解釈は、個人によって異なるはずである。従って、ここでは個人のパーソナリティと状況との関係を強度バランス  $|b/a|$  の視点で検証する。

パーソナリティ測定 日本語版 NEO-PI-R (The Japanese Revised NEO Personality Inventory: Shimonaka,

Nakazato, Gondo, & Takayama, 1998) より選択した、第 1 因子 (外向性、以降 E) と第 2 因子 (神経症傾向、以降 N) を測定する 10 項目についてパーソナリティ測定を行った。

実際の測定には 43 のフィラー項目 (NEO-PI-R における第 3 因子から第 5 因子を測定する項目と、Horino, 1987 による達成動機尺度項目から構成) と上記の 10 項目をランダムに組み合わせたものを使用し、Internet Explorer 6.0 で動作する WEB アプリケーションによって回答を得た。実験に参加した 118 人のうち、78 人がこの測定に参加し、実験の 2 ヶ月後に一斉に測定を行った。測定が終了するまで、被験者には 2 か月前の実験との関係を説明しなかった。被験者は 2 つのパーソナリティ尺度得点に基づいてそれぞれ神経症傾向高群/低群 (High-N/Low-N)、外向性傾向高群/低群 (High-E/Low-E) に分類された。被験者全体の平均値に基づいて分類した。

得られた結果に対し、被験者個人の強度バランスについて 2 要因の分散分析を 2 セット行った。要因はパーソナリティと実験条件であった (**High-N/Low-N** × **Over/Under** と、**High-E/Low-E** × **Over/Under**)。その結果、**High-N/Low-N** × **Over/Under** の分散分析では有意な交互作用が ( $p < 0.05$ )、**High-E/Low-E** × **Over/Under** の分散分析では有意な 2 つの主効果が確認された。図 3 に示されるように、**High-N/Low-N** × **Over/Under** の分散分析における交互作用は、**High-N** 群において状況効果がなくなってしまうことによる。すなわち、神経症傾向の比較的高い被験者は、リスク的な状況に依存しない帰納的推論を行っていたことになる。一方で、**High-E** 群、**Low-E** 群ともに状況効果は確認されるが、**High-E** 群では状況とは独立に強度バランスが大きくなり、従って外向性傾向の比較的高い被験者は、負事例と結論の類似性をより重視した帰納的推論を行っていたことになる。

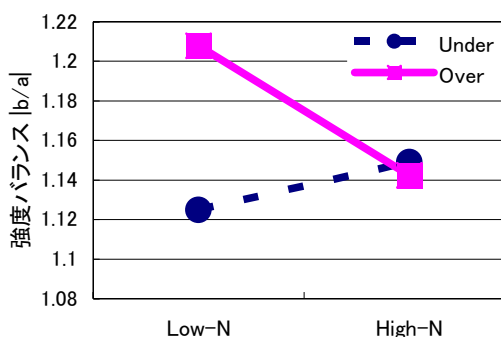


図 3. 神経症傾向と実験状況との交互作用

## 考察

本研究は帰納的推論のカーネル関数モデルが状況とパーソナリティの相互作用を明らかにする可能性を示してきた。このモデルは帰納的推論の評定を2つの類似性、正事例—結論の類似性と負事例—結論の類似性から説明する。2つのモデルパラメータは正事例の類似性と負事例の類似性の評定における強度バランスを表現する。パラメータ推定(回帰分析)の結果、帰納的推論の状況効果を説明できるだけでなく、パーソナリティと状況の相互作用も説明できることが明らかになった。

強度バランスについての2要因の分散分析では、実験条件と神経症傾向の有意な交互作用が確認された。この結果は、神経症傾向の高い個人が、低い個人のようにリスクの状況に応じて正事例の類似性と負事例の類似性間の強度バランスを調節していないことを示している。神経症傾向の高さが一般的に周囲の雰囲気に影響されやすく、情緒が安定していない傾向を示していることを考えると、リスク状況の違いによる影響を受けないというこの結果は一見矛盾しているように見える。ただし、本研究の実験における2つのリスクの状況の違いはリスクの大きさではなく、リスク回避の(帰納的推論における)方向であることに注目すると、帰納的推論において状況の違いに対処する戦略の違いなのではないかと考えることができる。図1からわかるように、2つのリスク条件における実験刺激の違いは、評定中、目の前に提示される配点表である。神経症傾向に関わる本研究の結果は、この情報を帰納的推論に利用するかしないかという戦略の違いだったのではないだろうか。ただし、本研究の結果からは、これ以上の推測はできない。今後の研究課題として、被験者を増やして交互作用の頑健性を確認したり、配点表の提示方法に工夫を凝らすなどの必要があるだろう。

一方で実験条件と外向性傾向の両方の主効果が確認された分散分析結果については、外向性傾向の高い被験者がより負事例の類似性を重視しているということが明らかになった。この結果は、外向性傾向の高い個人はより広範な情報に注目することと関連しているのではないだろうか。しかしこの場合も、神経症傾向に関わる交互作用の結果の解釈と同様にこれ以上の推測はできず、主効果の頑健性や、課題の表示方法に着目した新たな実験が必要となるだろう。

以上の本研究で明らかになったことは、解釈という視点は非常に限定されたものだが、少なくとも本研究で取り扱ったモデルが表現する帰納的推論の強度バランスが状況と評定者のパーソナリティで異なり、そのバリエーションが帰納的推論における課題戦略の違いを反映しうることは明らかになったといえる。

## 謝辞

この研究は日本学術振興会特別研究員制度の援助と、東京工業大学21世紀COE「大規模知識資源の体系と活用基盤の構築」の援助を受けて行われた。

## 参考文献

- Deerwester, S., Dumais, S., Furnas, G., Landauer, T., and Harshman, R. (1990). *Indexing by Semantic Analysis*. *Journal of the Society for Information Science*, 41, 6, 391-407.
- Horino, M. (1987) Analysis and reconsideration of the concept of achievement motive. *The Japanese journal of educational psychology* 35(2),148-154. (In Japanese)
- Hofmann, T. (1999). Probabilistic latent semantic indexing. *Proceedings of the 22nd International Conference on Research and Development in Information Retrieval :SIGIR '99*. 50-57.
- Osherson, D. N., Smith, E. E., Wilkie, O. Lopez, A., and Shafir, E. (1990). Category-Based Induction. *Psychological Review*, 97, 2, 185-200.
- Pereira, F., Tishby, N., and Lee, L. (1993). Distributional clustering of English words. *Proceedings of the 31st Meeting of the Association for Computational Linguistics*. 183-190.
- Rips, L. J. (1975). Inductive judgment about natural categories. *Journal of Verbal Learning and Verbal Behavior*, 14, 665-681.
- Sakamoto, K., & Nakagawa, M. (2007). Risk Context Effects in Inductive Reasoning: An Experimental and Computational Modeling Study. *Proceedings of the Sixth International and Interdisciplinary Conference on Modeling and Using Context*. Kokinov, B. et al. (Eds.): CONTEXT2007, Springer LNAI 4635, pp. 425-438.
- Sakamoto, K., & Nakagawa, M. (2008). A Computational Model of Risk-Context-Dependent Inductive Reasoning Based on a Support Vector Machine. *Proceedings of the third international conference on Large-scale Knowledge Resources*. Tokunaga, T., and Ortega, A. (Eds.): LKR2008, Springer LNAI 4938, pp.295-309.
- Simonaka, J., Nakazato, K., Gondo, Y., and Takayama, M. (1998). Construction and factorial validity of the Japanese NEO-PI-R. *The Japanese Journal of Personality*, 6, 2, 138-147. (In Japanese)
- Vapnik, V. (1992). *The Nature of Statistical Learning Theory*. Springer.