

論理の幾何的モデルに基づいたルールと事例の協調推論の枠組

高島 文次郎, 森田 千絵, 月本 洋

(株) 東芝 研究開発センター

本論文ではルールと事例を統一的に表現し、それらを用いた新しい推論方式を提案する。提案する推論方式は、ルールをデフォルトルールと見なし、事例によってルールの不備を補うという考え方方に基づいている。知識の表現には論理の幾何的モデルにおける論理ベクトルを用いる。命題は論理ベクトルにより表現することが可能で、それに不確定要素を付加することにより曖昧な命題も扱うことができる。デフォルトルールや事例の論理ベクトルに不確定要素を付加することにより、ルールと事例の協調推論を可能にしている。

A Framework for Rule and Case Based Reasoning Based on a Topological Model for Logics

Bunjiro Takashima, Chie Morita, and Hiroshi Tsukimoto

Research and Development Center, Toshiba Corporation

70, Yanagi-cho, Kawasaki-shi, Kanagawa, 210 Japan

This paper describes a new inference in which rules and cases are represented uniformly. It stands on the idea that the rules are defaults and the cases are exceptions to the rules. For representing the knowledge, we use the logical vectors in a topological model for logics. Propositions are represented by logical vectors. We can treat uncertain propositions by adding uncertain factors to the logical vectors. Therefore we can infer with rules and cases.

1 はじめに

エキスパートシステムは専門家の持っている知識をルールという形式で保持し、ある問題を解決する際に、ルールに基づいて推論を行なっている。これをルールベース推論（RBR）と呼ぶ。RBRでは知識が If-Then 形式で記述されており、推論結果が得られた場合にどのルールを使用したかが明らかであるために、なぜそのような結論が生成されたかを容易に説明することができる。しかし、専門家のもつている知識を獲得することは困難であり、知識獲得ボトルネックと呼ばれる問題が表面化している。そのため専門家自体が存在しない分野や、理論や方法が確立されていない分野に適用するのは困難である。

もう一つの推論方式として、過去の事例を蓄積しておき、その中から現在直面している問題に類似したものを検索し、その事例を問題に適合するように修正して解とする事例ベース推論（CBR）がある。CBRでは新しい事例が蓄積されることが知識獲得に対応している。ルールを獲得するよりは事例を獲得する方が容易であるので、一般には RBR におけるような知識獲得の問題は起きにくい。しかし、事例だけでは解空間を完全に覆うことはできないし、事例間の整合性を維持することが困難なためどの事例を利用するかにより異なった結果が得られる場合がある[4]。

近年、上述したような問題を解決するために、RBR と CBR を融合した推論方法が研究されている[1][2][3][5]。しかしそれらのほとんどは、RBR と CBR のうちのどちらかを主体とし、ルールと事例のうちのどちらかに写像してその範疇で推論を行なったり、RBR と CBR を交互に用いて推論を行なうというものである。しかしルールと事例を統一的に扱っていないために、ノイズによる影響や推論の効率に関する定量的な議論を行なうこととは難しい。

筆者の一人は論理の幾何的モデルを提案した[6]。そのモデルを用いると命題論理は論理ベクトルと呼ばれるベクトルで表現することができる。論理ベクトルの各々の要素が事例に対応するため、ルールと事例を統一的に表現していると言える。論理の幾何的モデルでは命題の情報量が定義されているので、命題の情報量を減少させることによってあいまいな命題を扱うことができる。また、ノイズの影響や推論効率に関する定量的な解析を行なうことができると考えられる。

本論文では、ルールと事例を協調させて推論を行な

う方式の一手法として、ルールと事例を論理ベクトルで表現し、論理空間においてそれらを統一的に扱う推論方式を提案する。その基本となるのはルールをデフォルトルールとして扱い、事例によりルールを補うという考え方である。ただしすべてのルールをデフォルトルールとして扱うではなく、公理として扱われるルールも存在するとする。またここでの事例の扱い方はその発生確率が意味を持ち、従来の事例ベース推論における事例検索、修正という手順は行なわれない。

2 論理の幾何的モデルと帰納学習アルゴリズム

本章では論理の幾何的モデルとそのモデルに基づいた帰納学習アルゴリズムについて簡単に説明する。

2.1 論理の幾何的モデルと論理ベクトル

命題論理の幾何的モデルを用いることにより命題をベクトルで表現することができ、その情報量を定義することができる。そのため、曖昧な命題を情報量の欠如した命題として扱うことが可能となる。また、確率ベクトルを論理ベクトルへ変換することにより、事象から命題を得ることができる。なお詳細については[6]を参照。

次に論理ベクトルについて簡単な例を用いて説明する。いま命題 X, Y に対するそれぞれの論理変数を x, y としたとき、 $X \vee Y$ という命題に対する論理関数は

$$x + y \quad (1)$$

と表現できる。これをカルノー図で示すと図1のようになる。




図 1 2 変数のカルノー図

図1を見ればわかるように、この式は 2 変数の論理空間の 4 つの基底

$$\{xy, x\bar{y}, \bar{x}y, \bar{x}\bar{y}\} \quad (2)$$

を用いると

$$1 \cdot xy + 1 \cdot x\bar{y} + 1 \cdot \bar{x}y + 0 \cdot \bar{x}\bar{y} \quad (3)$$

と表すことができる。2変数の命題はすべて、この4つの基底を用いて上式と同様に表すことができる。この4つの基底のことをアトムと呼ぶ。また命題 $X \vee Y$ の論理ベクトルとは、式3の係数のベクトルであり、下のようになる。

$$(1, 1, 1, 0) \quad (4)$$

ここで4つの基底は下に示すように2変数の論理空間の単位ベクトルとなっている。

$$xy = (1, 0, 0, 0) \quad (5)$$

$$x\bar{y} = (0, 1, 0, 0) \quad (6)$$

$$\bar{x}y = (0, 0, 1, 0) \quad (7)$$

$$\bar{x}\bar{y} = (0, 0, 0, 1) \quad (8)$$

古典論理命題では論理ベクトルの各要素の値は $\{0, 1\}$ である。例えば2変数の場合は図2に示す Hasse 図の各格子点がそれぞれひとつの命題に対応している。文献[6]では非古典論理命題を扱うためにこの値を $[0, 1]$ と拡張した。すなわち図2の格子点以外の点も命題であると解釈する。




図2 2変数の論理空間の Hasse 図

2.2 命題の帰納学習アルゴリズム

本節では論理の幾何的モデルに基づいた帰納学習アルゴリズムの概略について説明する。詳細は[7]を参照。

1. 確率データを確率ベクトルに変換する。

事象が各々論理ベクトルのアトムに対応し、その発生頻度を各要素の値としたベクトルが頻度ベク

トルである。確率ベクトルは事象の発生頻度を発生確率に変換したベクトルである。頻度ベクトルを $d = (d_i)$ 、確率ベクトルを $p = (p_i)$ としたとき頻度ベクトル d から確率ベクトル p を推定する式は式のようになる。

$$p_i = d_i/D \quad (i = 1, 2, 3, \dots, n) \quad (9)$$

ここで $D = \sum_{i=1}^n d_i$ であり、 n は論理ベクトルのアトムの数を表す。

2. 確率ベクトルを論理ベクトルに変換する。

確率ベクトル p から論理ベクトル f への変換は次式のようになる。

$$f = (2^{H\epsilon/2} / |p|)p \quad (10)$$

ここで $H\epsilon = -\sum_{i=1}^n (p_i \log_2 p_i)$, $|p| = \sqrt{\sum_{i=1}^n p_i^2}$ である。

3. 論理ベクトルを古典論理ベクトルで近似する。

式10で得られる論理ベクトルに対応する命題は一般には非古典論理命題である。これを古典論理ベクトルに近似するためには、もとの論理ベクトルに最も近い格子点とすればよい。従って古典論理ベクトル $g = (g_i)$ は以下のように求められる。

$$g_i = \begin{cases} 1 & f_i \geq 0.5 \text{ の時} \\ 0 & f_i < 0.5 \text{ の時} \end{cases}$$

4. 古典論理ベクトルを古典論理命題に変換する。

古典論理ベクトルの各要素が表す命題の論理和をとることにより古典論理命題が得られる。例えば2変数の場合、論理ベクトルが $(1, 1, 1, 0)$ であった時の論理閾数は $xy + x\bar{y} + \bar{x}y$ である。

5. この論理命題を簡略化する。

上の例の場合だと簡略化された命題は $X \vee Y$ となる。

2.3 論理ベクトルの演算

論理ベクトルの論理演算は以下のようにして行なう。2つの論理ベクトルを $f = (f_i), g = (g_i)$ としそれらが独立事象であった場合、論理ベクトルの論理積、論理和、否定はそれぞれ次式で求められる。

$$f \cdot g = (f_i \cdot g_i) \quad (11)$$

$$f + g - f \cdot g = (f_i + g_i - f_i \cdot g_i) \quad (12)$$

$$1 - f = (1 - f_i) \quad (13)$$

3 ルールと事例の協調推論 - 論理の幾何的モデルの応用 -

前章では論理の幾何的モデルに基づいた帰納学習アルゴリズムについて述べた。この帰納学習アルゴリズムによって、事例の集合について一般的に成り立つ命題を得ることができる。本章では事例から得られた命題と、命題で表現されたルールの両方を用いて推論を行なうための枠組について述べる。

3.1 論理ベクトルを用いた推論

いま帰納学習によって得られた命題を C とする。このとき推論条件 A に対する推論結果 X を以下のように求めることができる。

$A \rightarrow X$ である X は

$$C \rightarrow (A \rightarrow X)$$

を満たす。この式は次のように変形できる。

$$\begin{aligned} \bar{C} \vee (\bar{A} \vee X) &\Leftrightarrow (\bar{C} \vee \bar{A}) \vee X \Leftrightarrow \overline{C \wedge A} \vee X \Leftrightarrow \\ (C \wedge A) &\rightarrow X \end{aligned}$$

これより X は $C \wedge A$ よりも意味の狭い命題であることがわかるが、ここでは $C \wedge A$ を解とする。

命題が論理ベクトルで表現されている場合でも上に示した通り、ある命題の論理ベクトルと推論条件の論理ベクトルの論理積をとることにより、推論結果の論理ベクトルを得ることができる。最終的に推論結果は論理ベクトルを古典論理命題に変換、簡単化することにより得られる。

3.2 ルールと事例の協調推論の枠組

次にルールと事例の協調推論の方法について述べる。本報告で述べるルールと事例の協調推論はルールや事例を命題で表現し、与えられた推論条件に対してルールと事例から導かれる結論を解とする。

ここでは、個々のルールをそれぞれ一つの命題で表現し、また、過去に観測された事例の集合から一つの命題を生成して推論に用いる。ルールを表す命題は専門家から獲得され、事例を表す命題は観測結果をある命題として表現する。論理ベクトルの基底はそれぞれが一種類の事例に対応しており、各事例の発生確率により論理ベクトルの要素の値が決定される。その論理ベクトルを命題と見たものがここでの事例の命題である。

推論条件に対する結論は、ルールと事例の両方の命題によって肯定された命題を結論として生成するために、

ルール、事例、推論条件の3つの命題の論理ベクトルの論理積をとることによって得る。

しかし、ルールが完全に正しいものではない場合や、事例から得られる命題がその問題の本質的確に表現できていない場合があり、そのときには正しい解がそれらの命題によって否定される場合がある。そこで、それらの命題と矛盾する命題が完全に否定されることを避けることが必要である。

通常の命題論理ではある命題が真であれば、それと反する命題は偽である。すなわち「 A である」という命題が真であるならば、「 A でない」という命題は偽になり完全に否定される。命題論理の幾何的モデルでは、「 A である」という命題の情報量が減少した「 A であろう」というような命題を扱うことができる。

本論文でのルールと事例の協調推論では、命題の論理ベクトルに不確定要素を付加することにより上のようないくつかの命題の情報量の減少を実現する。ただし、情報量が減少した命題は、命題の意味が変わるのであって、命題の真理値は真であると考える。このことにより、不完全なルールや事例から得られる命題によって否定されていた命題を解として生成することが可能となる。

本論文で提案する事例とルールの協調推論の概要を以下にまとめる。また、その処理を図示したものを図3に示す。

1. ルール、事例、推論条件の論理ベクトルを生成する。
2. ルールは通常のルールとデフォールトルールとに分類される。デフォールトルールは一般的には成り立つが、その例外も存在することがありうるルールである。ルールのうちデフォールトルールであるものの論理ベクトルに不確定要素を付加する。
3. 事例の論理ベクトルに不確定要素を付加する。
4. ルール、事例、推論条件の論理ベクトルの論理積をとり、推論結果の論理ベクトルを得る。
5. 推論結果の論理ベクトルの解釈を行なう。

以下では上記の処理について詳しく説明する。

3.3 論理ベクトル生成

- ルールの論理ベクトル

ルールは複数個存在するが、それぞれが




図3 論理ベクトルの処理

$$A \rightarrow B \quad (14)$$

という命題論理で表現されているとする。これは連言(conjunction)、選言(disjunction)、否定(negation)のみを用いて表現することができ、以下のようにになる。

$$\bar{A} \vee B \quad (15)$$

最終的にはこれを論理空間で直交関数展開したものが、ルールの論理ベクトルとなる。

• 事例の論理ベクトル

命題論理の幾何的モデルでは、確率ベクトルと論理ベクトルを一対一対応させている。しかし実際には、事例のそれぞれの発生確率を正確に知ることは困難である。そこで、ここでは発生している事例の頻度からその確率を推定して用いる。

事例は頻度ベクトルという形式でその発生頻度が保存されており、それぞれの事例が論理ベクトルのアトムすなわち各属性がとりうる属性値の積で表現されるものに対応する。頻度ベクトルを論理ベクトルに変換するには、まず頻度ベクトルから確率ベクトルを推定し、確率ベクトルから論理ベクトルを生成する。

事例の論理ベクトルは第2.2節で示した帰納学習アルゴリズムで確率ベクトルを論理ベクトルに変換するところまでのステップで得られる。

• 推論条件の論理ベクトル

推論条件の論理ベクトル化もルールの論理ベクトル化と同様である。すなわち、推論条件を積和標準形に整形した後、論理空間で直交関数展開することにより論理ベクトルが得られる。

3.4 論理ベクトルへの不確定要素付加

• 事例の論理ベクトルへの不確定要素付加

事例を表す論理ベクトルに不確定性を付加するため、頻度が0でない事例の係数は通常の論理ベクトルの係数(> 0)とし、頻度が0事例の係数として係数0の代わりに $\beta(0 < \beta < (0 \text{ でない論理ベクトルの要素の最小値}))$ を導入する。図4にその例を示す。

β を導入した理由について述べる。確率ベクトルを論理ベクトルに変換する式は(10)であるが、一般には事例の正確な確率ベクトルを知ることは不可能であり、ここでは式(9)を用いて頻度ベクトルから確率ベクトルを推定した。事例数が多くなると、この変換によってかなり正しい確率ベクトルが生成できるが、事例数が少ない場合には正確な確率ベクトルとは掛け離れたものとなる。とくに今までに発生していない事例は頻度が0であるから、その確率も0ということになり、論理ベクトルのその事例に対する要素の値も0となる。しかし、論理ベクトルのある要素が0であると、ルールの論理ベクトルでのその要素の値が0でなくともそれらの論理積をとった段階で、その要素の値は0になってしまふ。言い換えるとルールで陽に述べられていたとしても、その事例が今までに発生していなければ、ルールで述べている結論が得られないということになる。このような事態を回避するために、事例の論理ベクトルの要素の値を0を β に置き換える。また、 β の大きさは今までに発生している事例のうち、最も頻度が小さいものの値を越えてはならない。

• ルールの論理ベクトルへの不確定要素付加

ルールは常に正しいルールと一般的に正しいルール(デフォールトルール)の2種類に分類されているとする。ルールをデフォールト化するために、ルールの論理ベクトルに不確定性を付加する。通常論理ベクトルの要素は0または1であるが、デ

確率ベクトル (頻度ベクトル)	論理ベクトル (ab , $a\bar{b}$, $\bar{a}b$, $\bar{a}\bar{b}$)
$(10, 5, 3, 0)$	$(1.41, 0.71, 0.42, 0)$
	\downarrow 不確定要素付加
	$(1.41, 0.71, 0.42, \beta)$
	$(0 < \beta < 0.42)$

図 4 事例の論理ベクトルへの不確定要素付加

フォールトルールの論理ベクトルでは、係数 0 の代わりに不確定さを表す係数 α ($0 < \alpha < 1$) を導入する。

ルールの論理ベクトルの不確定性について説明する。図 5 は 1 変数の命題の Hasse 図であり、原点を中心にして半径 1 の円弧が情報量 1 の命題を表している。いま A という命題があるとする。これは図の点 $(1, 0)$ に対応する。一方、情報量 0 の命題として $A \vee \bar{A}$ という命題を考える。これは図の点 $(1, 1)$ に対応する。このとき、命題論理の幾何的モデルでの拡張した論理空間では命題 A から命題 $A \vee \bar{A}$ へと推移していく途中の命題を扱うことができる。その命題は $A \vee \alpha \bar{A}$ ($0 < \alpha < 1$) と表すことができ、「おそらく A である」というような意味になる。これは図の点 $(1, \alpha)$ に対応する。この α が 1 に近づくにつれて命題の情報量は減少していく。ルールのデフォールト化すなわち不確定性の付加もこの考え方に基づいている。




図 5 1 変数の論理空間の Hasse 図

ルールのデフォールト化には 2 通りの解釈が考えられる。ひとつはルール自体の持っている情報量が減少したという考え方である。すなわち、 $A \rightarrow B$ (または $\bar{A} \vee B$) というルール自体の情報量が減少すると、 $(\bar{A} \vee B) \vee \alpha(\bar{A} \vee B)$ にルールが推移

する。図 6 にその例を示す。もう一つはルールの結論部の命題の情報量が減少したという考え方である。すなわち、 $A \rightarrow B$ というルールの結論部の命題の情報量が減少すると、結論部の命題は B ではなく $B \vee \alpha \bar{B}$ ということになる。従って $A \rightarrow B$ に対するデフォールトルールは $A \rightarrow (B \vee \alpha \bar{B})$ となる。図 7 にその例を示す。どちらの考え方でも最終的には同一の論理ベクトルが得られる。

命題論理	論理ベクトル (ab , $a\bar{b}$, $\bar{a}b$, $\bar{a}\bar{b}$)
$A \rightarrow B$ (または $\bar{A} \vee B$)	$(1, 0, 1, 1)$
	\downarrow デフォールト化
$(\bar{A} \vee B) \vee \alpha(\bar{A} \vee B)$	$(1, \alpha, 1, 1)$

図 6 ルールの不確定要素の付加 (1)

命題論理	論理ベクトル (ab , $a\bar{b}$, $\bar{a}b$, $\bar{a}\bar{b}$)
$A \rightarrow B$	$(1, 0, 1, 1)$
	\downarrow デフォールト化
$A \rightarrow (B \vee \alpha \bar{B})$	$(1, \alpha, 1, 1)$

図 7 ルールの不確定要素の付加 (2)

3.5 論理ベクトルの解釈

この段階で得られる論理ベクトルの要素は一般に実数値を持っており、さらに不確定要素が付加されている可能性がある。このような論理ベクトルから通常の命題論理を生成することを論理ベクトルの解釈と呼ぶ。

論理ベクトルの解釈の方法についてはまだ議論の余地があるが、ここでは、論理ベクトルの要素の値がもつとも大きいアトムがその論理ベクトルに対応する命題であるとする。

4 例

ここではバルブの材質選定の問題に、ルールと事例の協調推論を用いた例を示す。バルブの材質選定とは、バルブがどのような条件で使用されるかによって、バルブの材質を決定する問題である。

バルブの使用条件および材質を表 1 に示す。

表 1 バルブの使用条件と材質

属性	属性値	
温度	高温	低温
圧力	高圧	低圧
酸を含むかどうか	含む	含まない
材質	普通鋼	ステンレス

この例での論理ベクトルは $2 \times 2 \times 2 \times 2 = 16$ 次元のベクトルで表現される。これは属性「温度」の属性値が「高温」と「低温」の 2 値、属性「圧力」の属性値が「高圧」と「低圧」の 2 値、属性「流体が酸を含むかどうか」の属性値が「含む」「含まない」の 2 値、属性「材質」の属性値が「普通鋼」「ステンレス」の 2 値であり、それらの全ての組合せの数である。

いま、以下のルールと表 2 に示される事例があるとする。

ルール 1：酸を含む → ステンレス

ルール 2：酸を含まない → 普通鋼

表 2 では各行が一種類の事例に対応し、右端の数字がその事例の発生頻度を表している。この表の右端の 16 個の数字を一つのベクトルと見ると、それが事例の頻度ベクトルとなる。

表 2 事例データ

	温度	圧力	酸	材質	頻度
1	高温	高圧	含む	普通鋼	0
2	高温	高圧	含む	ステンレス	15
3	高温	高圧	含まない	普通鋼	4
4	高温	高圧	含まない	ステンレス	9
5	高温	低圧	含む	普通鋼	0
6	高温	低圧	含む	ステンレス	8
7	高温	低圧	含まない	普通鋼	4
8	高温	低圧	含まない	ステンレス	9
9	低温	高圧	含む	普通鋼	4
10	低温	高圧	含む	ステンレス	8
11	低温	高圧	含まない	普通鋼	2
12	低温	高圧	含まない	ステンレス	9
13	低温	低圧	含む	普通鋼	7
14	低温	低圧	含む	ステンレス	6
15	低温	低圧	含まない	普通鋼	10
16	低温	低圧	含まない	ステンレス	3

また、以下の 2 つの推論条件があるとする。

条件 1：高温 \wedge 低圧 \wedge 酸を含む

条件 2：低温 \wedge 高圧 \wedge 酸を含まない

このとき、ルール 1、ルール 2、事例の不確定性を付

加した論理ベクトル、および推論条件 1 に対する推論結果を表す論理ベクトル、推論条件 2 に対する論理ベクトルはそれぞれ表 3, 4 のようになる。この表の縦に並んで 16 個の数字がそれぞれ一つの論理ベクトルである。表の左端の数字は表 2 の左端の数字と対応している。

ここで α_1 がルール 1 の不確定要素、 α_2 がルール 2 の不確定要素、 β が事例の不確定要素を表し、

$$\alpha_1 = 0.4 \quad (16)$$

$$\alpha_2 = 0.4 \quad (17)$$

$$\beta = 0.1 \quad (18)$$

とする。

表 3 条件 1 に対する推論

	ルール 1	ルール 2	事例	条件 1	論理積 1
1	α_1	1	β	0	0
2	1	1	1.82	0	0
3	1	1	0.49	0	0
4	1	α_2	1.10	0	0
5	α_1	1	β	1	$\alpha_1\beta$
6	1	1	0.97	1	0.97
7	1	1	0.49	0	0
8	1	α_2	1.10	0	0
9	α_1	1	0.48	0	0
10	1	1	0.97	0	0
11	1	1	0.24	0	0
12	1	α_2	1.10	0	0
13	α_1	1	0.85	0	0
14	1	1	0.73	0	0
15	1	1	1.22	0	0
16	1	α_2	0.37	0	0

条件 1 に対する推論結果の論理ベクトルの要素のうち、その値が 0 でないものは次の 2 つである。

$$\text{高温} \wedge \text{低圧} \wedge \text{酸を含む} \wedge \text{普通鋼} \quad (19)$$

$$\text{高温} \wedge \text{低圧} \wedge \text{酸を含む} \wedge \text{ステンレス} \quad (20)$$

ここで、(19) の $\alpha_1\beta$ の値は (16), (18) より 0.04 である。従って (20) が採用され、材質として「ステンレス」を用いるという結論が得られる。これはルール 1 を適用した場合に得られる結論と同様である。

次に条件 2 に対する推論結果の論理ベクトルの要素のうち、その値が 0 でないものは次の 2 つである。

$$\text{低温} \wedge \text{高圧} \wedge \text{酸を含まない} \wedge \text{普通鋼} \quad (21)$$

$$\text{低温} \wedge \text{高圧} \wedge \text{酸を含まない} \wedge \text{ステンレス} \quad (22)$$

表 4 条件 2 に対する推論

	ルール 1	ルール 2	事例	条件 2	論理積 2
1	α_1	1	β	0	0
2	1	1	1.82	0	0
3	1	1	0.49	0	0
4	1	α_2	1.10	0	0
5	α_1	1	1	0	0
6	1	1	0.97	0	0
7	1	1	0.49	0	0
8	1	α_2	1.10	0	0
9	α_1	1	0.48	0	0
10	1	1	0.97	0	0
11	1	1	0.24	1	0.24
12	1	α_2	1.10	1	$1.10\alpha_2$
13	α_1	1	0.85	0	0
14	1	1	0.73	0	0
15	1	1	1.22	0	0
16	1	α_2	0.37	0	0

ここで、(22) の $1.10\alpha_2$ の値は (21) の 0.24 よりも大きい。従って (21) が採用され、材質として「ステンレス」を用いるという結論が得られる。これはルール 2 を適用した場合に得られる結果とは反している。

推論条件 1 に対する推論結果は、ルール 1 に反する事例がなかったためにルール 1 が適用されたのと同様の結論が得られた。一方推論条件 2 に対する推論結果は、ルール 2 に反する事例が多かったために、結果的にルール 2 が適用されなかつたということを示している。ただし、どのような結論が得られるかは不確定要素にどのような値をつけたかに依存する。

以上のように、本報告で提案したルールと事例に基づく推論方式では、ルールがデフォルトルールに対応し、ルールに反する事例が少ないと場合はルールに基づいた推論結果が得られるが、ルールに反する事例が多くなると事例に基づいた推論結果が得られる。

5 考察

5.1 属性および属性値

論理ベクトル表現を用いる場合には、あらかじめ全ての属性およびその属性値が与えられている必要がある。しかし、一般的に推論システムを構築する際の過渡的な状況では、ルールや事例が蓄積されていくごとに属性や属性値が新たに認識されたり、あるいは認識の変化により属性や属性値が必要なくなったりする。そのような属性や属性値の認識に変化があった場合には、現在保持さ

れているルールや事例をそれに伴って整形しなければならない。

表 5, 6 に属性および属性値がそれぞれ追加、削除された場合のルールと事例の取り扱い方法をまとめた。このうち、属性が追加された場合の事例の取り扱い方には二通り考えられる。一つは、今まで存在していた属性が新たに考慮が必要であると認識された場合であり、保持されている事例をその属性のとる属性値の予想される分布に従って分割する必要がある。もう一つは、今まで存在していなかった属性が（例えば技術革新などで）新たに発生した場合には、過去の事例に対してその属性値を埋めることはできない。

属性が追加された場合にルールの修正をする必要がない理由は、今回提案する推論方式ではルールが一般的な規則を表し、事例によりそれを補うという性質による。つまり、ルールが不完全であっても事例が蓄えられることにより、良質な推論結果を生成できるようになる。しかし、属性の追加によりルールがあまりにも非現実的なものとなつた場合には、人間が介入してルールを修正する必要があると考えられる。

表 5 属性が変更された場合のルールと事例の取り扱い

	追加	削除
ルール	何もしない。	その属性値を含むルールを削除する。
事例	(追加された属性が全く新しい属性であるかそうでないかによって扱い方が変わる。)	その属性の属性値で展開されている事例を 1 つの事例にまとめ、事例の頻度はまとめられた事例の合計とする。

表 6 属性値が変更された場合のルールと事例の取り扱い

	追加	削除
ルール	何もしない。	その属性値を含むルールを削除する。
事例	何もしない。	その属性値を含む事例を削除する。

属性に関する問題として、現在の段階では階層的な属性まで考慮していないという点がある。階層的な属性とは例えば、地域という属性に対して {関東, 関西, …} という属性値があり、それぞれがさらに属性値を持つ（関

東ならば {東京, 神奈川, …}) というものである。現段階では階層的な属性に対しては、階層を展開して末端の属性値を直接その属性の属性値としなければならない。

また階層的に属性を扱うメリットとしては、論理ベクトルの次数が小さくなるという点以外に、推論で得られる結果の抽象度を変えることができるという点が挙げられる。つまり、階層の下層まで展開して推論を行なった場合には、得られた結果は曖昧性が少ないが、階層の下層まで展開しなかった場合には、抽象度の高い結論が得られる。これは CBR の事例検索という観点からは、上位の階層を扱うことにより検索範囲を広げていることになり、解の柔軟性という観点からは、上位の階層を扱うことにより解の範囲が広くなるということを意味する。

属性値に関する問題としては、論理ベクトルを用いるという性質上、属性値が連続値をとるような属性を扱えないことがある。この問題に対処するためには、その属性に何らかの方法でクラスを定義する必要がある。例えば、事例のデータとしては連続値を保持しておき、事例から論理ベクトルを生成する際には、まず、数値データをクラスタ分析により、いくつかのクラスに分類して、後は離散値として扱うことにより、実用上はこの問題を回避できると考えられる。

5.2 論理ベクトルの次数

論理ベクトルはすべての属性に対する属性値の数の積の次元のベクトルとなる。すなわち、属性の数を N_A 、属性 i の属性値の数を n_{vi} としたときに、論理ベクトルの次数 D_{LV} は

$$D_{LV} = \prod_1^{N_A} n_{vi} \quad (23)$$

となる。

しかし、実際的な問題に適用しようとした場合には、論理ベクトルの次数 D_{LV} は非常に大きくなるために膨大な計算量が必要となり、計算量をいかにして軽減するかが問題となる。

論理ベクトルの次数の問題に対処する一つの手段は、論理ベクトルの演算において、推論条件として与えられる論理ベクトルの要素が 0 となる部分は無視するということである。これは通常は D_{LV} 次元の論理空間全体を扱っていたのに対し、推論条件によってその部分空間だけを扱うことができるということによる。同様に属性を階層的に扱い、必要とする解の抽象度あるいは精度によって属性を展開するレベルを変えるという方法も考えられ

る。

さらに、推論において注目する属性とそうでない属性が予め指定できるのであれば、必要な属性については論理ベクトルの展開は必要なくなるので、この観点からも次数の削減が考えられる。

5.3 論理ベクトル化

論理ベクトルの次数がある程度大きくなるのは避けられない。そこで、推論の実行効率を上げるためにルールと事例をあらかじめ論理ベクトル化しておくことが考えられる。さらに、ルールと事例の論理ベクトルの論理積を先に計算しておき、その結果と推論条件の論理ベクトルとの論理積をとることにより、推論効率は上がる。すなわち、推論条件が与えられた時に行なう処理は、推論条件を論理ベクトル化し、その論理ベクトルとルールと事例の論理ベクトルの論理積との論理積をとり推論結果の論理ベクトルを得、推論結果の論理ベクトルを解釈して推論結果を得るということになる。

ルールと事例の論理ベクトルの計算が必要になるのは以下の時である。

- ルールが編集された時。(追加、削除、修正)
- 事例が追加された時。
- ルールや事例の不確定性が変化した時。

このようなときも、ルールや事例のそれぞれの論理ベクトルを記憶しておくことにより、必要最小限の計算のみを行なわなければならない。

5.4 不確定要素

5.4.1 ルールにおける不確定要素

ルールは複数存在するが、それぞれのルールに同一の不確定性を用いることは好ましくない。なぜなら、ルールの正確さは、問題の性格や人為的な要素に左右されるので、それぞれのルールに対して不確定要素 α の値は異なってくる。そこで、個々のルールには固有の不確定要素 α が割り当てる必要がある。しかし、 α の値の決定方法を定式化するのは困難である。

これに対する案としては以下のものを検討している。

- 各々のルールに不確定要素 α の初期値をルールの入力時に指定する。
- 推論の実行後に新しい事例が獲得されるが、その事例と反するルールの不確定性を増加させ、事例

と同様の結論を導出するルールの不確定性を減少させる。

5.4.2 事例における不確定要素

頻度ベクトルから生成された確率ベクトルは実際の確率ベクトルとは異なるという主張により、事例の論理ベクトルに不確定要素を付加した。しかし、厳密にはこの段階で不確定性を付加した論理ベクトルは、確率ベクトルから論理ベクトルへの写像の中にはない。従って確率ベクトルの段階で不確定要素を付加して、全事象の確率の和が1となるように正規化する方が良いと考えられる。これは、現在の不確定性の付加の方法で、とくに推論結果が問題になる訳ではないが、今後不確定要素の値による推論効率の影響や、間違った事例が蓄積された場合の影響を解析する際に問題となる可能性があるからである。

不確定要素の値の決定方法にも問題がある。第3.4節でも述べたように、 β の範囲を ($0 < \beta < (0$ でない論理ベクトルの要素の最小値)) としたが、実際にその値を決定する際には適当な値を割り当てる必要がある。しかし不確定性の値の決定方法についても定式化できていないのが現状である。

また、現在は頻度から求めた確率が0である全ての事例に対して同一の不確定性 β を与えているが、これは現実的であるとは言えない。例えば、明らかにあり得ないような属性の組合せとなっている事例は最初から排除されるべきであり、その場合には論理ベクトルのその事例に対する係数として β ではなくまさに0とするべきであると考えられる。

5.5 論理ベクトルの解釈

論理ベクトルの解釈では、論理ベクトルのアトムの係数が最も大きいものが推論結果であるとした。別の方針としては、係数の大きいものから解に優先度をつけて、あとはユーザーに選択してもらうということも考えられる。また、係数の比較において不確定要素が含まれている係数についての評価を変えるということも考えられる。例えば、0.2と $\alpha\beta$ とを比較する時には $\alpha\beta$ がほぼ0.2であったとしたら、 $\alpha\beta$ を係数とするアトムよりも0.2を係数とするアトムが解として採用されるべきである。これは発生している事例を重視するという立場から見て、発生していない事例に対して β という不確定性を付加することにより、すでに発生している事例が軽視される

ということが起こるのを避ける必要があると考えられるからである。

6 おわりに

本報告では命題論理の幾何的モデルに基づいたルールと事例の協調推論の枠組について述べた。この推論方式は、ルールが一般的な規則を表現しており、事例によってその例外を補うという考え方方が基本となっている。今回提案した推論方式では、事例が蓄積されていくことによって、以前導出されていた推論結果とは別の推論結果が得られる可能性があるという点において、一種の非単調推論方式であるといえる。また、ルールと事例を論理ベクトルで表現することによって、統一的に扱っているという点も一つの特徴である。

しかし前章でも述べたように本手法には改良、検討の余地が数多く残されている。今後はこれらの点について詰めていきたい。

参考文献

- [1] Andrew R. Golding and Paul S. Rosenbloom. Improving Rule-Based Systems through Case-Based Reasoning. *Proceedings of the Ninth National Conference of Artificial Intelligence*, pp. 22 - 27, 1991.
- [2] Edwina L. Rissland and David B. Skalak. Combining Case-Based Reasoning: A Heuristic Approach. *Proceedings of the 12th International Joint Conference on Artificial Intelligence*, pp. 524 - 530, 1989.
- [3] 新田 克己. 法的推論システム HELIC-II. 人工知能学会誌, Vol. 7, No. 4, pp. 603 - 607, 1992.
- [4] 小林 重信. CBRの現状と課題. 人工知能学会, 知識ベースシステム研究会資料, SIG-KBS-9102, pp. 29 - 38, 1991.
- [5] 安信 千津子, 山田 弘, 源田 晋司, 鎌田 芳栄. ルールベース推論と事例ベース推論の統合化の一方法. 人工知能学会誌, Vol. 7, No. 6, pp. 1087 - 1095, 1992.
- [6] 月本 洋. 命題論理の幾何的モデル. 情報処理学会論文誌, Vol. 31, No. 6, pp. 783 - 791, 1990.
- [7] 月本 洋. 確率データからの帰納学習. 人工知能学会誌, Vol. 7, No. 5, pp. 870 - 876, 1992.