

4C-1

## 多領域を対象にした漸増的な類推

服部雅一 永田守男

(慶應義塾大学理工学部)

### 1. はじめに

知識情報処理の分野において、現在の知識ベースでは、知っていることには答えられるが、知らないことに対しては少しも対処できないというような幅の狭さ、脆弱さが大きな問題となっている。

この問題に対する解決の方法として、適切な知識が存在しない場合、類似な知識を「拡大解釈」して代用する類推 (analogical reasoning) は、有効なもの一つであると考えられている。

本論文では、類推の機構に対して多くの領域を対象にした一般的でダイナミックなメカニズムを導入することによって、類推の能力を向上させることを提案する。

### 2. 類推の問題点と本論文の目的

類推とは次の4つのプロセスから成り立っている。

- ① 既知の領域候補の認識 (recognition)
- ② 既知の領域から目標領域への写像 (elaboration)
- ③ 写像結果への評価、修正 (evaluation)
- ④ 推論結果の強化 (consolidation)

従来は、①に関して、単一の既知の領域 (ソース領域) 理論を未知の目標領域 (ターゲット領域) に写像し新たな知識を導き出すという類推システムが多く、②に関して、2つの領域のオブジェクト間の照合対応全ての組合せについてそれぞれの対応の得点を合計し、それが全体として最高得点となるような対応付けを選択することで最良部分照合を見つけることを目的とした部分パターン照合形式で発展してきた。

しかしこのような方法で成功するのは大変によく似たソース領域とターゲット領域においてであり、ソース領域からターゲット領域への写像は不完全な状況間の対応付けに過ぎず、現状の類推によって獲得した結果は、一般に最適な結果を導くとはかぎらない。

一方、人間は、発想を得るために日常的に最も多用する推論は、類推であると言われている。この場合に、

人間は、ある未知の問題に直面した時、既知の似たような多くの領域から部分的に必要となる知識を取り出しながら、新しい理論を合成して、その問題を説明し、後に矛盾が起きればまた他の領域を部分的に用いて修正していくようなメカニズムを持っていると思われる。

そこで、本論文は、多くの領域からのソース領域の選択及びターゲット領域への写像の仕方を仮説と考え、仮説生成と検証・修正のプロセスを導入し、事実・規則の入力によってデータの内部構造を変更していく動的なメカニズムを提案する。

更に1つの質問に対して類推結果が多く得られる場合、全ての解が質的に同等であるとは限らないので常にその時点での最適解を選択するようにし、事実によって裏付けされた推論結果は一般化して類推における学習の結果とした。

### 3. 漸増的な類推 (incremental analogy)

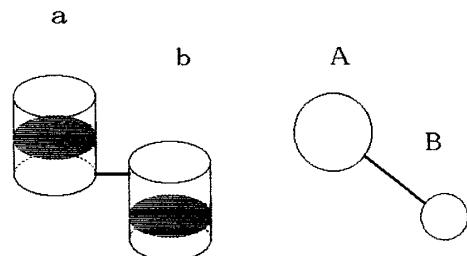


図 1

例えば、図のような高い位置にある水の入った容器 a と低い位置にある水の入った容器 b を考える。この状態の変化を考えると、経験から『熱力学第2法則』に基づく「熱い物体 A と冷たい物体 B が接触している」場合を連想し、「容器 a の体積は減り、容器 b の体積は増える」を「物体 A の温度は低くなり、物体 B の温度は高くなる」と写像する。しかし物体 A の温度の減少は物体 B の温度の増加に等しくないのに対して、容器 a の体積の減少は容器 b の体積の増加に等しいのでこれに関しては現象を説明できない。そこで経験から

Incremental Analogical Reasoning for

Multi-Domain

Masakazu HATTORI and Morio NAGATA

Keio University

化学の『質量保存の法則』に基づく「反応前の質量の和と反応後の質量の和は等しい」ことから連想してこれを説明する。このように類推を考える上でソース領域は多く存在しなければ、より最適な類推結果を得ることができない。

従って、類推を行うときソース領域の選択の仕方(①)、写像の仕方(②)によって質問に対する結果が大きく異なってくる。ソース領域をどの領域からどの部分取ってくるのか、またその部分をターゲット領域にいかに写像させるかといった不確かな事実を仮説と考えて、ATMSによる仮説集合の管理を行う。

ATMSとは、TMSと同様にデータ依存関係に基づいてコンテキストの一貫性を管理するものであるが、仮説の組合せを考慮することにより多重コンテキストに対処する。結果としてTMSは、1つの無矛盾な信念の状態を維持するのに対して、ATMSは、複数の無矛盾な信念の状態を扱うことができる。

しかしこのような方法をとると、計算量の爆発を起こす危険性があるが、この点に関しては、次のような手段によって対処する。まず、様々な領域の要素に関する知識をフレーム構造で知識ベースに蓄るようにしている。これによって要素間の無駄な写像をせず、仮説空間の増大を防ぐ。同様に、類似的な知識(「どの領域とどの領域が似ている」といった知識)によってもソース領域の選択に関する不必要的仮説を生成するのを防ぐ。また、矛盾する仮説の組合せの排除などによっても仮説空間を絞り込む。

以下に本システムの構造の概要を示す。

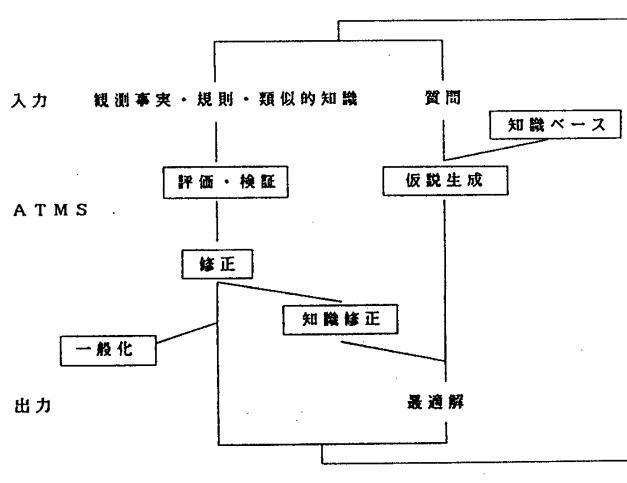


図2

評価・検証は、仮説集合によって支持された情報が

入力された事実・規則と無矛盾であるかを調べることと、仮説集合によって支持された情報が入力された事実・規則によって正当性が裏付けられるかどうか調べることによって行う。

ここでの修正とは、評価・検証によって仮説空間を変更することである。そのときあるソース領域とターゲット領域が類似していない・類似している、ある写像の仕方が最適でない・最適である等の最適解のヒューリスティクスが得られ知識修正部に蓄えられる。

このヒューリスティクスとして、他に

- ・少ない仮説に支持された解を優先する
- ・同一のソースの仮説によって支持されている解を優先する
- ・Coherent (完備している)
- ・Most (たくさんの論理式ができるだけたくさん導く)
- ・Least (Mostの逆)

などの直観的な原則も存在する。

一般化は、事実によって裏付けされた類推結果を規則の形に変換して強化し、ターゲット領域の理論として扱うことを可能にする。

#### 4. まとめ

局所的な解法になりがちの類推に多くの領域を対象にした仮説生成・検証・修正という漸増的なメカニズムを導入し、人間的なダイナミックな推論として統一的な解法を与えた。

今後は、EBL(説明に基づく学習)、CBR(事例に基づく推論)、DBR(差異に基づく推論)などの学習・推論機構との融合、或は情報に例外的な情報を扱う非単調論理などの導入を考慮していく予定である。

#### 参考文献

- [1] Greiner, R.: Learning by Understanding Analogies, Artificial Intelligence, Vol. 35, 1988, pp81-125
- [2] Falkenhainer, B.: An Examination of the Third Stage in the Analogy Process (Verification-based Analogical Learning), AAAI-87, 1987, pp260-263
- [3] Hall, R.: Computational Approaches to Analogical Reasoning, Artificial Intelligence, vol. 39, 1989, pp39-120