

コスト依存アブダクションの提案

Cost-Sensitive Abduction for an Agent

山田 誠二
Seiji Yamada

馬場口 登
Noboru Babaguchi

大阪大学 産業科学研究所
I.S.I.R. Osaka University

This paper describes the novel method for preferring hypotheses with cost in abduction or hypothetical reasoning. Traditional studies on the preference have focused on the way to select the optimal hypothesis with a syntactic criteria: the minimum explanation is best. Unfortunately the criteria does not contain the cost for observing the environment in order to verify the selected hypothesis. However, considering an agent which observes and recognizes the environment with hypothetical reasoning or abduction, we can not ignore the cost for observing the environment. Therefore we propose preference using cost, uncertainty and utility of observing and verifying hypothesis. We argue our method is more suitable for an agent acting the environment than syntactic criteria, and evaluate the performance with the experiments in pattern recognition.

1 はじめに

本研究では、環境において行動するエージェントの対象の認識を仮説推論（あるいは、アブダクション）の枠組みとして捉え、そこにおける仮説選好の新しい方法を提案する。エージェントは、観測により得られた対象の情報と自分が持っている対象モデルを照合することにより対象を認識するが、現実的にはその情報は部分的であり、不確実性を伴ってしか得られないため、初期の観測だけではモデルと完全に照合することができない。そのため部分的な情報に基づき、適切と考えられるモデルを仮説として採用し、その仮説を検証するために次の観測行為を行う。しかし、ここで問題となるのは、アブダクション [井上 92] により得られる仮説が複数存在する場合、どの仮説を選好 (preference) するかである。従来の仮説の選好基準は、仮説数が最小なものを選択する等の方法であったが、観測を含むすべてのエージェントの行為は、コスト、不確実性、効用を伴うため、それらを考慮した仮説の選好を行うのが適切であるというのが、我々の主張である。そこで本研究では、このようなエージェントの環境認識に適した仮説の選好方法を提案し、2次元平面上において移動するエージェントによる簡単なパターン認識における実験によりその有効性を示す。

2 仮説推論と仮説の選好問題

まず、簡単に仮説推論 [石塚 92] に触れておこう。一般的には、仮説推論 (hypothetical reasoning) とは、真偽のはっきりしていない事柄を仮に真として (つまり、仮説を立てて) 推論を続け、結果的に問題が解決できれば、先に立てた仮説は正しいとする推論方式である。具体的には、知識ベースを、常に成り立ちかつ、無矛盾な知識の集合

K と、常に成り立つとは限らない知識の集合 H に分ける。そして、ゴール G が与えられたときに、まず K から G を演繹的に証明できるかを試みる。そして、 K だけでは証明できないとき、次の条件を満たす H の部分集合 h を求め、以降、このような h を仮説候補と呼ぶ。

$$\begin{cases} K \cup h \vdash G \\ K \cup h \text{ は無矛盾} \end{cases}$$

ここで問題となるのは、上の条件を満たす仮説が複数個ある場合に、どれを選好するかである。一般には、形式的な選好基準である仮説の最小性が用いられる。つまり、 h のどの真部分集合 h' も $K \cup h' \vdash G$ を満たさないという基準である。しかし、このような基準は正しいが弱いものであり、なお複数の仮説が候補として残り得る。さらに選好を行うには、論理の枠を越えた基準が必要になると考えられる。

これまでのアブダクションあるいは仮説推論の選好に関する研究では、仮説候補を確認するための新しい事実の観測にかかるコスト等は、直接的には扱われてこなかった。一方、仮説推論の分野では、仮説の検証を含む枠組であるにもかかわらず、対象領域として回路の設計及び故障診断などが多く扱われた故か、仮説検証にかかるコストはほとんど無視されている。しかし、仮説の生成そして新たな観測による仮説の検証を行うエージェントを考えた場合、その観測に伴うコスト、仮説の信頼性、さらにその仮説が正しかった場合にエージェントが得る効用の3つを考えた選好が適切であると考えられる。

3 仮説推論としての対象認識

それぞれの認識対象には、それを認識することによりエージェントが得ることのできる効用が割り当てられている。本研究におけるエージェントの目的は、単位時間あたりにできるだけ高い効用を獲得することである。こ

のような状況でエージェントは、モデルによるパターン認識を行う。まず、認識対象について部分的に観測された観測事実から、対象がエージェントのもつどのモデルに対応するかの仮説を立て、次に観測すべきことを決定し、実際にその観測を行い、得られた事実からまた仮説を生成するという処理を繰り返していく。このような手続きは、仮説推論の枠組みで扱える。以上の手続きをまとめると次のようになる。なお、本研究で主に扱うのは、

3. 仮説選好である。
1. 環境の観測：観測を行い、対象のデータ集合を観測事実として得る。
2. 仮説生成：観測事実を基に仮説推論により、仮説候補の集合を生成する。
3. 仮説選好：仮説候補を選好して、最も適切な仮説を一つ選び、その仮説を検証するために、次に行うべき観測を決定する。

4 コストに依存した仮説選好と観測の決定

ここでは、我々の提案する仮説選好について説明して行く。まず、本研究が扱う対象認識の仮説推論の枠組について述べ、その上で仮説選好とそれによって次の観測を決定する方法を示す。

4.1 仮説推論による対象認識の枠組

まず、対象認識における仮説推論の構成要素を挙げる。

- 観測事実 O ：観測事実の集合。
- 仮説集合 H ：既与の仮説の集合。
- 仮説候補 h ： $\{h : K \cup h \vdash O, h \subseteq H, K \cup h \text{ は無矛盾}\}$ 。仮説候補 h は、知識 K と合わせて観測事実を演繹的に証明可能な、仮説集合の部分集合。
- 候補集合 F ：ある観測事実に対するすべての仮説の集合。
- 観測行為 A ：ある仮説を検証するために必要な観測。
- 知識 K ：エージェントの知識。対象モデルと仮説の矛盾に関する知識を含む。
- 効用 U ：ある仮説による認識が成功した場合にエージェントが得る利得。
- 仮説の信頼度 S ：ある仮説がどれだけ確からしいかの度合いで、 $S \in [0, 1]$ とする。初期観測の誤差、モデルの信頼性等から算出。
- 観測のコスト関数 $C(A)$ ：観測 A に要するコストを返す関数。単位は、時間とする。

4.2 選好関数による観測決定

前節のような枠組において、仮説の選好値を返す選好関数を下式のように定義する。この関数は、概ね期待効

用に対応しており（厳密には、 S は確率ではないが）、決定論的視点から妥当なものとする。

$$\text{仮説 } h \text{ の選好関数： } P(h) = \frac{U}{C(A)} \cdot S \quad (1)$$

上記の選好関数により、候補集合中の各仮説に対し選好値を計算し、その値が最大である仮説 h を、最も適切な仮説として、その仮説を検証する観測 $A(h)$ を実行する。

5 パターン認識における実験

以上において述べた仮説選好の有効性を調べるため、2次元平面上の移動・観測を繰り返して、簡単なパターン認識をするエージェントを実装し、実験を行った。

5.1 実験環境

エージェントが対象認識をする環境は、 100×100 の2次元格子平面である。それぞれのセルは、0 か 1 の2値の値を持つ。エージェントは、 5×5 のウィンドウを持って格子上を移動することが可能で、そのウィンドウ内のデータだけを参照できる。

格子上には、図 1 に示すように 5×5 の大きさをもつ7種類のパターンが散在しており、パターン T と + の2つに対してのみ、効用が割り当てられている。エージェントは、効用をもつ2つのパターンのモデル (5×5 のビットマップ) だけを持っており、以下のような行動をとる。

1. 現在のウィンドウでパターンが見えるなら、2. へ。見えないなら、見えるようになるまで、ランダムに移動する。
2. 部分的に見えるパターンとモデルとの部分マッチングを行い、仮説候補を生成する。
3. それぞれの仮説候補について、選好関数により選好値を計算し、その最大の仮説を検証する移動を行い、観測する。
4. 完全マッチングすれば、エージェントはその効用を獲得し、ランダムに移動して、1. へ。なお、その対




図 1: 問題平面 (部分)

象パターンは、平面上から消滅する．完全マッチングしなければ、1.へ．

5.2 適用

上記のような状況におけるエージェントの対象認識は、我々の枠組で扱える．ここでは、各要素がどのように記述されるかを、図2で説明していく．図中では、 5×5 (原点は、左上)の対象パターン P の一部が、エージェントのウィンドウ W 中に見えている．今、説明を簡単にするため、その対象パターンには、 T のモデル m_T だけが、候補として考えられるとする．(実際は、 $+$ のモデル m_+ も候補になって、それらの選好が行われる．)このときの仮説推論の各要素は、以下ようになる．以降、 $cell(X, Y, V)$ は、対象パターン上の座標 (X, Y) のセルの値が V であることを意味する．

- 観測事実：

$$\begin{aligned} O &= W \cap P \\ &= observed(cell(0, 0, 1), cell(0, 1, 1), cell(0, 2, 1), \\ &\quad cell(1, 0, 0), cell(1, 1, 0), cell(1, 2, 1)). \end{aligned}$$

- 仮説集合 H ： P のうち、見えていない部分についての仮説集合．

$$\begin{aligned} H = \{ & cell(0, 3, 0), cell(0, 3, 1), cell(0, 4, 0), cell(0, 4, 1), \\ & cell(1, 3, 0), cell(1, 3, 1), cell(1, 4, 0), cell(1, 4, 1), \\ & cell(2, 0, 0), cell(2, 0, 1), cell(2, 1, 0), cell(2, 1, 1), \\ & cell(2, 2, 0), cell(2, 2, 1), cell(2, 3, 0), cell(2, 3, 1), \\ & cell(2, 4, 0), cell(2, 4, 1), cell(3, 0, 0), cell(3, 0, 1), \\ & cell(3, 1, 0), cell(3, 1, 1), cell(3, 2, 0), cell(3, 2, 1), \\ & cell(3, 3, 0), cell(3, 3, 1), cell(3, 4, 0), cell(3, 4, 1), \\ & cell(4, 0, 0), cell(4, 0, 1), cell(4, 1, 0), cell(4, 1, 1), \\ & cell(4, 2, 0), cell(4, 2, 1), cell(4, 3, 0), cell(4, 3, 1), \\ & cell(4, 4, 0), cell(4, 4, 1) \} \end{aligned}$$

- 仮説候補： $h = M \cap \bar{O}$ (ここで、 M は、 O とモデルとの重なりを調べるにより得られるモデルの候補)




図2: 対象の部分パターン

$$\begin{aligned} h_1 = \{ & cell(0, 3, 1), cell(0, 4, 1), cell(1, 3, 0), cell(1, 4, 0), \\ & cell(2, 0, 0), cell(2, 1, 0), cell(2, 2, 1), cell(2, 3, 0), \\ & cell(2, 4, 0), cell(3, 0, 0), cell(3, 1, 0), cell(3, 2, 1), \\ & cell(3, 3, 0), cell(3, 4, 0), cell(4, 0, 0), cell(4, 1, 0), \\ & cell(4, 2, 1), cell(4, 3, 0), cell(4, 4, 0) \} \end{aligned}$$

- 候補集合 $F = \{h_1\}$

- 観測決定関数： A は、図2の v の移動．

- 知識 K ：

% あるモデルから観測事実が説明可能．
 $observed(cell(0, 0, 1), cell(0, 1, 1), cell(0, 2, 1),$
 $cell(1, 0, 0), cell(1, 1, 0), cell(1, 2, 1)) : - m.t.$

∴

% モデルのビットマップ．

$m.t : -$

$cell(0, 0, 1), cell(0, 1, 1), cell(0, 2, 1), cell(0, 3, 1),$
 $cell(0, 4, 1), cell(1, 0, 0), cell(1, 1, 0), cell(1, 2, 1),$
 $cell(1, 3, 0), cell(1, 4, 0), cell(2, 0, 0), cell(2, 1, 0),$
 $cell(2, 2, 1), cell(2, 3, 0), cell(2, 4, 0), cell(3, 0, 0),$
 $cell(3, 1, 0), cell(3, 2, 1), cell(3, 3, 0), cell(3, 4, 0),$
 $cell(4, 0, 0), cell(4, 1, 0), cell(4, 2, 1), cell(4, 3, 0),$
 $cell(4, 4, 0).$

∴

% 矛盾ルール

$inconsistent : - cell(1, 1, 0), cell(1, 1, 1).$
 $inconsistent : - cell(2, 1, 0), cell(2, 1, 1).$

∴

- 効用： $U = 100$ (T のとき), 10 ($+$ のとき)

- 仮説の信頼度： $S = 1 - \frac{d}{\|O\|}$

($\|O\|$ は、 O のセル数． d は、 O のセルのうち、モデルのマッチングしたセル数．)

- 観測のコスト関数 $C(A)$ ：観測 A のための移動したマンハッタン距離を、その観測のコストをする．

以上の設定により、選好関数が計算され、仮説推論の枠組で対象パターンの認識が行われる．

5.3 実験方法

本実験では、平面上の総パターン数は、50個に固定する．その内訳は、効用のある2種類のパターンが20個ずつ、効用のない5種類のパターンが2個ずつである．

時間は、観測のために移動するごとに、そのコスト分だけ進み、2000単位時間経ったときの獲得効用の合計を調べた．選好関数を以下の4種類に変えた場合それぞれについて、エージェントと50のパターンの初期位置の異なる10個の問題について実験し、平均値をとった．実験環境は、すべて SICSTUS Prolog で実装された．

$S + C + U$ ：式(1)の選好関数を用いた場合．

S ：式(1)の信頼度のみを評価した場合．

$S + C$ ：式(1)の信頼度とコストを評価した場合．

ランダム：選好をせず仮説をランダムに選択した場合．

5.4 実験結果

実験結果として、それぞれの条件での平均獲得得点を表 1 に示す。式 (1) の選好関数を用いた結果が最もよいことがわかる。信頼度 S は、大まかに仮説数最小基準に対応しており、後で触れる Tang のコスト依存学習の評価基準は、 $S+C$ に対応している。我々の提案した選好関数は、どちらよりも良い結果が得られている。しかし、表 1 からわかるように、この領域では、ランダムに仮説を選択してもかなりの効用を獲得できるため、それほど差異が出ていない。

表 1: 実験結果

$S+C+U$	S	$S+C$	ランダム
1230	1132	1176	995

6 関連研究

仮説候補の選好に関する初期の研究 [Kautz 86] では、最小な仮説を良いとする基準が用いられた。しかし、必ずしもそのような形式的基準では十分ではない。本研究では、環境を認識するエージェントの仮説推論において、その不十分性を指摘した。さらに、実験において、最小仮説基準に対応する信頼性だけによる評価よりも、観測コストや効用を導入した選好の方が優れていることを示した。

Poole は、理論比較の研究を行い、そこで人間は複数の説明の中から最も特殊な説明を選好すると考えた [Poole 85]。説明の特殊性の定義は、純粋に推論過程から導かれるものであり、そこにはある説明を確認するためにエージェントが観測を行うという視点はなく、当然観測に伴うコスト及び不確実性は考慮されていない。この点においては、國藤らの研究 [國藤 86]、松田らの研究 [松田 88] も同様である。また、主に自然言語処理において提案されたコスト依存アブダクション [Hobbs 93] においても、環境に働きかけるエージェントという視点はない。

Charniak らの研究 [Charniak 90] では、アブダクションにおけるコスト最小の説明の生成が、そのコストと確率と見なして、証明過程をベイジアンネットワークに変換した場合の事後確率最大化 (maximum a-posteriori) と等価であることを示した。そこで、観測事実に割り当てられたコストを我々の選好値と考え、Charniak らの枠組の部分と言える。最適な説明を求めることは、NP 困難であるが、本研究では、観測事実にだけコストを割り当て、仮説の選好値を選好関数で計算するだけなので、計算量的問題はない。それでも、実験に示したとおり、良好な結果が得られている。

本研究は、基本的考え方において、Tang の提唱したコスト依存学習 (cost sensitive learning) [Tang 93] を踏襲している。Tang は、ID3 による判別木生成において、その属性を実際にチェックするコストを採り入れた評価を行い、従来の情報量的基準のみからとは異なった判別木が生成された。本研究は、このような観測コスト依存の考

え方を、さらに不確実性と効用をも考慮して、仮説の選好において展開したものである。

7 まとめ

環境において対象を認識するタスクをもつエージェントの認識処理を仮説推論の枠組で捉え、そこにおける仮説の選好問題に対し、観測のコストと不確実性を考慮した選好を行う方法を提案した。また、2次元平面上を移動して、パターン認識を行うエージェントに我々の方法を適用し、その有効性を示した。

謝辞

コスト依存アブダクションに関する文献を教えていただいた井上克己先生 (豊橋科技大学)、大澤幸生先生 (大阪大学)、また実装に際し有益な助言を頂いた淡誠一郎先生 (近畿大学) に感謝いたします。

参考文献

- [Charniak 90] Charniak, E. and Shimony, S.E.: Probabilistic Semantics for Cost Based Abduction, *AAAI-90*, pp.106-111 (1990).
- [Hobbs 93] Hobbs, J.R. et. al.: Interpretation as Abduction, *Artificial Intelligence* Vol.63, pp.69-142 (1993).
- [Kautz 86] Kautz, A. and Allen, J.: Generalized Plan Recognition, *AAAI-86*, pp.32-37 (1986).
- [Tang 93] Tang, M.: Cost-Sensitive Learning of Classification Knowledge and Its Application in Robotics, *Machine Learning*, Vol.13 No.1, pp.7-34 (1993).
- [Poole 85] Poole, D.: On the Comparison of Theories: Preferencing the Most Specific Explanation, *IJCAI-85*, pp.144-147 (1985).
- [石塚 92] 石塚満: 仮説推論, 日本ファジィ学会誌, Vol.4 No.4, pp.620-629 (1992).
- [井上 92] 井上克己: アブダクションの原理, 人工知能学会誌, Vol.7 No.1, pp.48-59 (1992).
- [松田 88] 松田, 石塚: 仮説推論システムの拡張知識表現と概念学習機構, 人工知能学会誌, Vol.3 No.1, pp.94-102 (1988).
- [國藤 86] 國藤, 鶴巻, 古川: 仮説選定機構の一実現法, 人工知能学会誌, Vol.1 No.2, pp.228-237 (1986).