

EBL にとって説明とは何か

What is an Explanation for EBL?

山田誠二* 大阪大学産業科学研究所

Abstract

What is an explanation for Explanation-Based Learning? In this paper, we propose the answer to the question from a viewpoint of machine learning. First, we survey two methods, Similarity-Based Learning and Explanation-Based Learning, and find out difference between the two methods. As a result, we obtain unified view in which both SBL and EBL are considered as search in a space consisting of candidates of target concepts. From this viewpoint of search, the difference between SBL and EBL depends on knowledge for pruning a search space, which knowledge is called "Bias". Since an explanation and domain theory of EBL is used to uniquely distinguish a target concept from a lot of generalized concept descriptions, the explanation is considered as bias in EBL. The EBL's bias is far stronger than the SBL's one. Thereby, EBL's generalization can be done with just a positive example. We consider the most important contribution of EBL to machine learning is to find an explanation is used as a very strong bias.

Keywords

Explanation-Based Learning : 説明に基づく学習, Similarity-Based Learning : 類似に基づく学習, bias : バイアス, search : 探索, generalization : 一般化

* 山田 誠二 (Seiji Yamada)

〒567 大阪府茨木市美穂ヶ丘 8-1, 大阪大学産業科学研究所

(The Institute of Scientific and Industrial Research, Osaka University, 8-1, Mihogao-ka, Ibaraki-si, Osaka 567, Japan)

1. 緒言

人工知能 (artificial intelligence) 研究において、自ら学習するコンピュータの実現は、最重要課題の1つである。人工知能の黎明期以来、パラメタ学習、パーセプトロン、概念学習など、さまざまな学習手法が研究されてきた。その中で最も盛んに研究されている「例からの学習 (learning from examples)」の分野において、近年新しいパラダイムが台頭してきた。大量の訓練例 (training example) を必要とする従来の帰納的学習 (inductive learning) に対して、1つの訓練例から説明 (explanation) を用いて学習可能な「説明に基づく学習: EBL (Explanation-Based Learning)」が、それである。

EBL の出現により、これまでの帰納的学習は、「類似に基づく学習: SBL (Similarity-Based Learning)」として差別化され、EBL vs SBL という記号学習におけるパラダイムの対立が生じている。本論文では、EBL の重要概念である「説明」とは何であるのかを明確にし、対立する2つのパラダイムの本質的差異を検討した後、結果として統一的視点を提案する。「説明とは何か」、「EBL と SBL は本質的に異なるのか」という疑問が、本論文の動機になっている。

2. 「記号による例からの学習」とは、何を学習するのか

機械学習 (machine learning) は、暗記学習 (rote learning)、助言に基づく学習 (learning by taking advice)、例からの学習 (learning from examples)、類推による学習 (learning by analogy) などに分類される [Barr & Feigenbaum, 1981]。EBL, SBL は、共に「記号による例からの学習」に分類される。以下、この「記号による例からの学習」について述べる。

「記号による例からの学習」では、一般に教師 (teacher) から、学習システムに訓練例が与えられ、それを用いて学習が行われる。訓練例は、学習すべき目標概念 (goal concept) に含まれる具体例 (instance) である肯定例 (positive example) と、含まれない否定例 (negative example) からなる。そして、「例からの学習」とは、教師により与えられる目標概念の訓練例から、目標概念の内包 (intension) である概念記述 (concept description) を生成することである。この場合、肯定例は概念記述という内包についての外延 (extension) と見なせる。通常、肯定例は一般化

表 1 記号による例から学習の構成要素

<入力>	訓練例
<出力>	概念記述
<表現>	記号表現
<処理>	記号処理

表 2 SBLの構成要素

<入力>	訓練例, 一般化規則, バイアス
<出力>	概念記述
<表現>	一階述語表現
<処理>	バイアスを用いた概念空間の探索

(generalization) に使われ, 否定例は特殊化 (specialization) に使われる。

この概念記述及び訓練例が, 例えば, 述語論理 (predicate calculus) の論理式 (wff), つまり記号 (symbol) で表現され, かつ学習手続きが記号処理 (symbol processing) であるとき, その学習を「記号による例からの学習」と呼ぶ。ここで学習される目標概念は, それを肯定例から真となることが導かれ, 否定例からは偽となる論理式である。

以上をまとめると, 「記号による例からの学習」の定義は, 表 1 のようになる。これらの条件を満たす学習方式は, すべて「記号による例からの学習」と呼べる。表 1 には, 具体的な学習手続きが規定されていない。次章で述べる SBL は, 「記号による例からの学習」の一具体例となっており, その具体的な学習手続きが提供される。

3. 類似に基づく学習 : SBL 概要

本章では, SBL を概観する。従来の帰納的学習が, 訓練例の共通した特徴, つまり「類似性 (similarity)」を探索することによって, 一般化を行うことから, SBL という名称で呼ばれている。[Mitchell *et al.*, 1986]。SBL の具体的手法としては, Mitchell のバージョン空間 [Mitchell, 1977], Michalski の手法 [Michalski, 1983] など種々のものがあるが, 学習の効率, 概念記述空間の表現, 訓練例駆動 (training example driven), などの違いがあるだけで, 基本的には同様の処理を行なっていると考えるよい [Mitchell, 1982]。よって, 本章では個々の具体的手法にとらわれず, SBL の本質的な特徴について述べていく。まず, 一般的な SBL の構成を表 2 に示す [Utgoff, 1986]。

前述のように, SBL は, 「記号による例からの学習」の一つの具体的手法なので, SBL の構成要素のうち, 入力の一般化規則, バイアス (bias) 以外は, 記号による例からの学習の構成要素に対応している。よって, 次のような式が成り立つ。

$$\text{SBL} = \text{「記号による例からの学習」} + \text{一般化規則} + \text{バイアス} \quad (1)$$

ここでは、訓練例及び概念記述の表現、SBL 特有の入力である一般化規則とパイアス、そして SBL の学習手続きについて説明していく。

3.1 述語による概念記述

一般に、SBL において、訓練例及び概念（目標概念を含む）は、一階述語（first order predicate）の連言（conjunction）として表現される。もちろん、選言（disjunction）、存在限量子（existential quantifier）、高階の述語などを扱える表現を用いた研究もあるが、ここではそれらに立ち入らないことにする。

3.2 一般化規則

目標概念の生成手続き、厳密に言うと、目標概念を必ず含む概念記述集合の生成手続きは、あらかじめ SBL に組み込まれている。それが、一般化規則と呼ばれるもので、訓練例に一般化規則を繰り返し適用することにより、さまざまな一般性をもった概念記述が得られる。さらに、一般化規則の適用対象である概念記述と、それに適用した結果、得られた概念記述の間に、半順序関係（partially ordered relation）が成立し、概念記述空間が構成される [Mitchell, 1982]。SBL では、求めるべき目標概念が、必ずこの概念記述空間に含まれると仮定している。もし、含まれなければ、当然目標概念は獲得されない。

ここで、具体的な一般化規則を見ておこう。概念記述は、述語の連言で表わされているので、その形式に依存した統語的（syntactic）な一般化規則が用いられる。この規則は、対象領域によって、さまざまなものが用いられるが、ここでは典型的なものを以下にあげる [Michalski, 1983]。これらの一般化規則は、後の具体例で用いられる。なお、以降では、述語の大文字の引数は変数を、小文字の引数は定数を表わす。

- 条件削除規則（dropping condition rule）

概念記述中の述語を削除する。

例) $a(b) \wedge c(d) \wedge e(f) \Rightarrow a(b) \wedge c(d)$

$a(b) \wedge c(d) \wedge e(f) \Rightarrow a(b) \wedge e(f)$

$a(b) \wedge c(d) \wedge e(f) \Rightarrow a(b)$

(\Rightarrow は、一般化規則の適用を表わす)

- 変数化規則（turning constrains into variables rule）

概念記述中の述語の引数を定数から変数に変換する。ただし、別々の変数に変えるのでは、上記の条件削除規則と等価なので、ここでは複数の引数を同じ変数に変換する場合だけを扱う。

例) $a(b) \wedge c(d) \wedge e(f) \Rightarrow a(B) \wedge c(B) \wedge e(f)$

$a(b) \wedge c(d) \wedge e(f) \Rightarrow a(b) \wedge c(D) \wedge e(D)$

• 区間設定規則 (closing interval rule)


引数の値が数字の場合、その引数のある区間に一般化する。

例) $\text{weight}(65) \Rightarrow \text{weight}(X) \wedge X > 60$

• 一般化木上昇規則 (climbing generalization tree rule)

あらかじめ与えられている一般化木を上り、より一般的な概念記述に変換する。上記の3つの一般化規則とは異なり、この一般化規則の適用により、概念記述の述語が変化する。典型例として、LEX [Mitchell *et al.*, 1983] における不定積分のための概念木を以下に示す。

例) $\text{minus real number}(X) \Rightarrow \text{real number}(X)$



3.3 SBLの学習手続き

一般化規則により、概念記述空間が構成されると、学習の問題は、概念記述空間中で目標概念を探す「探索」の問題に還元できる。よって、SBLの学習手続きは、以下のように記述される。

- (1) 一般化規則を用いて、目標概念の候補である概念記述からなる概念記述空間を生成する。
- (2) 訓練例とバイアスにより、目標概念の探索を行なう。訓練例を満たす概念記述が得られれば、それが目標概念であり、学習は終了する。

(1)では、概念記述空間の生成を行なう。この空間は、一般化規則適用により生成された概念記述をノードとして、概念記述間の一般/特殊の半順序関係をアークとするネットワークとなる。通常は、任意の肯定例を1つとってきて、それに一般化

規則を適用して概念記述を生成し、さらにその記述に一般化規則を適用するということを繰り返し、概念記述空間を構成していく。この構成の方法において、訓練例によって一般化／特殊化が起動されるか(データ駆動型) [Mitchell, 1977], 一般化規則を適時適用してノードを生成し、訓練例をそのノードの妥当性の検証に用いるか(生成検査型) [Michalski, 1983], あるいは概念記述の空間のコンパクトな表現(バージョン空間) [Mitchell, 1977] などの違いはあるが、原理的には同様である。

処理(2)では、全ての一般化規則の適用により、生成された概念記述について、肯定例を満たし、否定例を満たさない記述を探索する。

3.4 バイアス

前述の一般化規則の例からわかるように、一般化規則の適用の仕方は、非常にたくさんある。例えば、条件削除規則の適用は、 n 個の述語の連言に対して、 n 個の要素を持つ集合の全ての部分集合の数だけ考えられる。また、変数化規則を適用する場合、複数の変数のうち、どれとどれを同じ変数と見なすかにより、多大な組合せがあるし、区間設定規則などは、実数で区切ると、無限に適用できる。さらに、これらの規則を組み合わせて適用して概念記述空間を構成するのが普通なので、その大きさは膨大なものになる。よって、強力な枝刈り (pruning) なしに、解を見つけることは不可能になる。枝刈り等の探索の効率化のための知識をバイアスと呼ぶ。通常、一般的な知識により枝刈りを行っても、大きな効果は得られないため、領域に依存した知識が用いられる場合が多い。一般にバイアスは、訓練例とは区別されるので、以下のように定義できる。

バイアスとは、目標概念の探索において、その効率化に用いられる知識のうち、訓練例以外のものである。

SBL で用いられる典型的なバイアスを、以下に示す [Utogoff, 1986]。

- 概念記述の候補の優先順位

記述が簡略な概念記述の候補、例えば、連言の述語が少ない候補を優先するというような評価基準。

- 一般化規則の制限

一般化規則の適用に対して、何らかの制限を加える。例えば、区間設

定規則は、10, 20, ……100 というように、10 刻みのみ許す、などである。

• 一般化規則適用の優先順位

ある概念記述に対し、複数の一般化規則が適用可能な場合、どの一般化規則から適用するかという優先順位。

上記のうち、概念記述の候補の優先順位は、比較的領域独立な一般的バイアスであるが、残りの2つは、強く領域に依存したバイアスの例である。また、当然ながら、概念木上昇規則の概念木及びそれを構成している概念記述言語などもバイアスに含まれる。

3.5 具体例

処理(1), (2)を具体例で説明していく。いま、「タバコを吸える国立大学生」という概念を学習すると考える。ただし、ここで「タバコを吸える」とは、物理的に吸えることではなく、合法的に喫煙が認められていることを意味する。記号による例題からの学習では、概念及び訓練例は述語で記述されるので、まずその記述述語を設定しなければならない。ここでは、目標概念の記述に十分な述語を以下のように設定する。 $/n$ の n は、引数の個数である。

性別/1, 年齢/1, 所属/1, 大学/1, 設立/2, 職業/2

これらの述語は、「タバコを吸える国立大学生」をいう概念を記述するために必要十分なものではなく、冗長なものも含まれる。しかし、現在の目標概念にとって不必要な述語でも、他の目標概念の学習には必要になる場合もあり、記述の汎用性を考えて、敢えて削除しないのが普通である。

これで、記述述語が決定したので、その述語を用いて訓練例を記述する。例えば、以下のような訓練例が与えられるとしよう。

〈肯定例 1〉

性別 (女) ∧ 年齢 (21) ∧ 所属 (北大) ∧ 大学 (北大) ∧ 設立 (北大, 国) ∧ 職業 (学生)

〈肯定例 2〉

性別 (男) ∧ 年齢 (21) ∧ 所属 (北大) ∧ 大学 (北大) ∧ 設立 (北大, 国) ∧ 職業 (学生)

〈肯定例 3〉

性別 (男) ∧ 年齢 (25) ∧ 所属 (九大) ∧ 大学 (九大) ∧ 設立 (九大, 国) ∧ 職業 (学生)

〈否定例 1〉

性別 (女) ∧ 年齢 (19) ∧ 所属 (北大) ∧ 大学 (北大) ∧ 設立 (北大, 国) ∧ 職業 (学生)

〈否定例 2〉

性別 (女) ∧ 年齢 (22) ∧ 所属 (早稲田) ∧ 大学 (早稲田) ∧ 設立 (早稲田, 個人) ∧ 職業 (学生)

〈否定例 3〉

性別 (男) ∧ 年齢 (30) ∧ 所属 (阪大) ∧ 大学 (阪大) ∧ 設立 (阪大, 国) ∧ 職業 (助手)

以上で、訓練例が与えられたので、表 2 における残りの入力である一般化規則とバイアスを設定する。

ここでは、一般化規則のうち、条件削除規則、変数化規則、区間設定規則の 3 つを用いる。多数ある一般化規則から、この 3 つを選択したこと自体が、既にバイアスになっている。ここで用いられている述語は、6 個なので、まず条件削除規則による概念記述の候補が 63 個あり、また変数化規則の適用だけでも、1000 個以上になる。最後に、区間設定規則であるが、この区間設定は、人間の年齢は 0~150 という知識があったとしても、 ${}_{151}C_2 - 150 = 11175$ という多くの可能性がある。さらに、これらをすべて組み合わせた数は、膨大なものとなり探索は現実的に不可能である。また、それらの候補から 1 つの正しい目標概念を得るために必要な訓練例の量も、膨大なものになるだろう。

この膨大な概念記述空間を削減するために、以下のようなバイアスを設定する。ただし、単純化のため、通常 SBL で用いられるバイアスよりも、はるかに強いバイアスを用いていることを断わっておく。

- ・バイアス 1：変数化規則に対し、「同じ値をもつ引数だけを同じ変数にする」という制限を設ける。
- ・バイアス 2：区間設定規則に対し、「18 または 20 で区切る」という制限

を設ける。

- バイアス 3：条件削除規則に対し、一度に削除する述語は1つだけとする。
- バイアス 4：条件削除規則，区間設定規則，変数化規則の順に適用する。
- バイアス 5：探索は，評価関数 $EF = (\text{その候補を満たす肯定例の個数}) - (\text{その候補を満たす否定例の個数})$ の値が最大の候補を選んで，縦型探索 (depth first search) [Winston, 1977] を行う。そして，すべての肯定例を満たし，すべての否定例を満たさないことが，目標概念の条件である。目標概念を見つけたら，探索は終了する。

注目すべき点は，これらのバイアスの多くは，対象領域に依存した知識から得られるもので，通常設計者によりシステムに組み込まれることである [Utgoff, 1986]。例えば，「人間の年齢は，社会的に 18 または 20 前後で区別される」という常識的知識に，バイアス 2 は起因しているし，バイアス 3 は，目標概念にとって，性別という 1 つの述語だけが，必要ないことから導かれる。

また，バイアスは SBL において，暗示的 (implicit) にシステムに組み込まれるという特徴がある。ここで「暗示的」と言うのは，その領域知識が，その知識そのものを表わす記述 (典型的には，宣言的 (declarative) 記述) として，システムに与えられるのではなく，一般化規則の条件の変更や概念記述の候補の選択手続きという形で与えられることを意味する。

さらに重要なことは，このような強力なバイアスは，学習されるべき目標概念があらかじめわかっている者でなければ，正確に設定できないことである。よって，システム設計者が，目標概念をあらかじめ想定して，その目標概念に向けて，学習を上手に誘導するようなバイアスが設定される。この誘導がなければ，現実的に SBL は学習できないといわれる [Michalski, 1983]。

これら 5 つのバイアスにより，探索空間は大幅に削減される。この探索空間全体を図示するのは，紙面の都合上無理なので，処理 (2) により探索される部分のみを図 1 に示す。この図は，肯定例 1 から縦型探索をしたものである。長方形が，それぞれ目標概念の候補であり，CN というラベルと EF の値が示されている。

まず，肯定例 1 に，バイアス 4 の優先順位により，条件削除規則が適用され，一つの述語だけが取り除かれて，C1～C6 の候補が生成される。このうち，C1 が EF

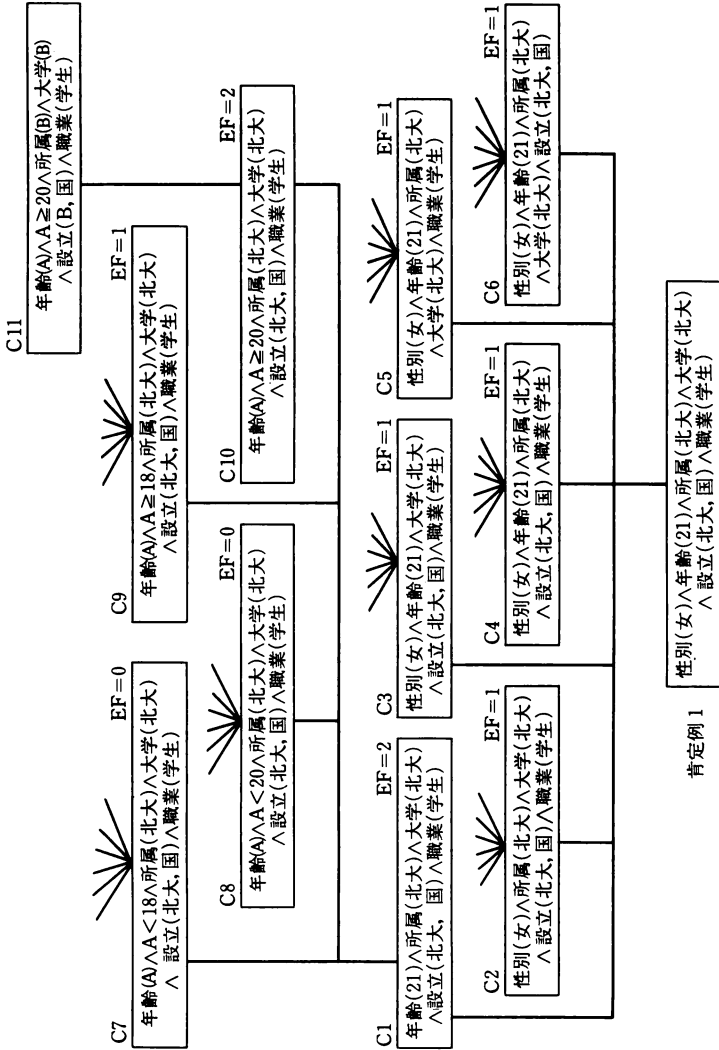


図 1 SBL の探索過程

=2で最大であり、選択される。しかし、C1は目標概念の条件を満たさないで、次に区間設定規則が適用され、C7~C10が生成される。C7、C8は、肯定例1自身を満たさないで、目標概念ではない。C9、C10のうち、EFが大きいのはC10なので、C10が選択される。C9では、年齢が「18歳以上」と過度に一般化(over generalization)されており、それが否定例1を含むために、EFの値が小さくなる。このように、否定例は、過度の一般化を抑える働きがある。そして、最後に変数化規則が適用される。この規則の適用は、「北大」の変数化だけである。こうして得られたC11は、すべての肯定例を満たし、すべての否定例を満たさないで、目標概念となり、探索は終了する。

ここで用いたバイアスは、特殊で非常に強力なものである。しかし、一般のSBLにおいても、一般的で統語的な知識(例えば、一般的な探索戦略)だけでは、探索空間が大きすぎて、実際には使いものにならないため、必ずバイアスを用いて、探索空間の削減を行なっている。このバイアスが正しくかつ強いほど、探索空間は縮小し、少ない訓練例で目標概念の記述を見つけることが可能となる。しかし、強いバイアスは、領域への依存性が強くなり、一般性は失われる。

4. EBL 概要

4.1 認知モデルとしてのEBL

われわれが、「タバコを吸える国立大学生」という概念を教師から教えてもらう状況を考えてみよう。少なくとも、SBLのように、教師が学習者にタバコを吸える国立大学生をたくさん見せて、黙って学習者に目標概念を考えさせるという状況はほとんどない。もちろん、そのようなSBL的状况が自然な場合もある。例えば、物理学者が未知の法則をデータから推測する場合などである。

しかし、通常、教師が「タバコを吸える国立大学生」という概念を学習者に教える際、ある肯定例について、それがなぜ目標概念の肯定例になるのかを説明する。このとき、まず「タバコを吸えること」、「国立大学」、「大学生」という概念を説明し、それらの組合せとして「タバコを吸える国立大学生」という目標概念を教えると考えられる。この教示の過程において、学習者は、SBLのように、教師から与えられた訓練例から目標概念の記述を推定して、その妥当性を大量の訓練例を用いて検証しているのではない。このような、説明をして人に教えるという人間にとってごく日常的に行われている行為が、これまで機械学習では、ほとんど扱われてこな

かったのではないだろうか。

では、説明はどのように形式化されるのだろうか。最も一般的と考えられるのは、論理的な証明を説明として扱うことである。実際、EBLのほとんどの手法が、証明を説明として用いている。

さらに、説明を機械学習に利用することは、技術的側面からみて、どのような利点があるのだろうか。まず、SBLにおいて、与えられた訓練例の、どの述語が目標概念に関連していて、どの述語が関連しておらず削除してもよいのかは、条件削除規則を適用して概念記述を生成し、訓練例を用いて検証しなければ決まらない。しかし、説明を用いると、ある述語が説明に必要なか否かにより、どの述語を削除すべきかを一意に決定できる。さらに、どの定数を変数に一般化するかも、SBLでは決定できないが、説明を利用すると、説明と矛盾しない範囲、あるいは証明可能な範囲で変数化すればよいから、これも一意に決まる。

つまり、説明を使って、目標概念が非常に効率よく学習できると考えられる。このように、教師により、なぜこの例が目標概念の肯定例であるのかを説明してもらい、その説明から学習していく手法を機械学習で実現したものが、「説明に基づく学習－EBL (Explanation-Based Learning)」である。以降でEBLの概要について述べる。

4.2 説明に基づく学習：EBL

EBLの要素技術として、最も広く用いられているのが、説明に基づく一般化：EBG (Explanation-Based Generalization) [Mitchell *et al.*, 1986; DeJong & Mooney, 1986] である。なお、EBLには、説明に基づく特殊化等の研究 [Minton, 1988] などもあるが、まだ確立されていないこともあり、EBLをEBGとほぼ同義で使うことが多く、本論文でも、EBGを用いた学習をEBLと称することを断わっておく。以降、[Mitchell *et al.*, 1986] をもとに若干の修正を加え、EBLを説明していく。

まず、EBLの構成を表3に示す。一般に、EBLの概念記述及び訓練列は、ホーン

表 3 EBLの構成要素

〈入力〉	訓練例, 目標概念, 領域理論, 操作性規準, 説明
〈出力〉	操作可能な概念記述
〈表現〉	ホーン節
〈処理〉	説明の生成, 一般化

節(horn clause)で表現されるので、以下でもその表現を用いる。小文字の文字列は定数を表わし、大文字で始まる文字列は変数を表わす。また、EBLにおいて、説明はシステム自身が生成しても、外部から与えられてもかまわないので、出力とも入力ともとれるが、ここでは入力に加えている。

表3から明らかなように、EBLも「記号による例からの学習」の一種であり、EBLの構成要素のうち、目標概念、領域理論、操作性規準、説明以外は、記号による例からの学習の構成要素に対応している。よって、次の式が成り立つ。

EBL = 「記号による例からの学習」 + 目標概念 + 領域理論 + 操作性規準 + 説明 (2)

以下に、入出力をより詳細に説明する。

〈入力〉

- ・ 目標概念(goal concept)：学習すべき目標概念を頭としてもつ規則節。
- ・ 訓練例：目標概念の肯定列。SBLの肯定例と同じ。ただし、EBLでは、肯定列を証明で用いる単位節(unit clause)の集合として扱う。
- ・ 領域理論(domain theory)：訓練例中の単位節で目標概念を証明するために必要な規則節(rule clause)及び訓練例以外の単位節。
- ・ 操作性規準(operationality criterion)：学習された概念記述が、満たすべき基準。
- ・ 説明：訓練例、領域理論を用いた目標概念の説明。入力として与えられてもよいし、学習システムが自動生成してもよいが、ここでは一応入力としておく。

〈出力〉

- ・ 操作可能な概念記述(operational concept description)：操作性規準を満たす目標概念の記述。

EBLで最も特徴的な点は、目標概念が与えられており、それを訓練例で証明するための領域理論も与えられていることである。よって、これらを使って、学習する前でも証明可能であれば、与えられた訓練例が目標概念の肯定例であるのか否かを判別できる。すると、EBLでは何を学習しているのだろうか。この疑問に答えるのが、操作性(operationality)という概念である。

操作性あるいは操作性規準という概念は、研究者の間で必ずしも統一されていない [DeJong & Mooney, 1986; Mitchell *et al.*, 1986; Keller, 1987]。しかし、本質

的なのは、「ある概念記述Aを用いた問題解決が、概念記述Bを用いたものより効率が上がる場合、概念記述AはBよりも操作性が高い」ということと考えられる。そして、操作性を上げるための条件を操作性規準という。つまり、操作性規準が満たされれば、操作性向上が保証されなければならない。操作性規準は種々のレベルで設定されるが、大別すると、概念記述言語の制限 [Mitchell *et al.*, 1986; DeJong *et al.*, 1986], 操作性向上の実験的な検証 [Keller, 1987] などがあるが、ここでの例では、前者が用いられている。また、概念記述が、操作性規準を満たす状態を操作可能 (operational), 満たさない状態を操作不可能 (unoperational) という。

この観点から、EBL では学習前でも、訓練例が目標概念の肯定例か否かの判別はできるが、その時点での目標概念の記述は、操作性規準を満たさず操作不可能で、その判別の効率は悪いとする。それに対し、学習された概念記述は、操作性規準を満たし操作可能であるとする。よって、EBL は操作不可能な概念記述を操作可能なものに変換する。つまり、操作化 (operationalization) するという役割を果たす [Keller, 1987]。これにより、パフォーマンスシステムの問題解決の効率が向上するわけである。この問題解決の効率向上が、EBL が学習である根拠である、とされている。

では、どのようにして、操作可能な概念記述が得られるのか、をSBLで用いた具体例で見たい。EBLの入力は、以下ようになる。

- 概念記述：タバコ学生
- 訓練例：SBL で用いた肯定例 1
- 目標概念：
タバコ学生 ← タバコ OK ∧ 国立大所属 ∧ 職業 (学生) (1)
- 領域理論：
タバコ OK ← 成人 (2)
成人 ← 年齢(A) ∧ A ≥ 20 (3)
国立大所属 ← 所属大学(B) ∧ 国立(B) (4)
所属大学(C) ← 所属(C) ∧ 大学(C) (5)
国立(D) ← 設立 (D, 国) (6)
- 操作性規準：訓練例の記述述語で表現される。

以上がEBLの入力である。これらを用いて、以下の2つの処理を行なう [Mitchell

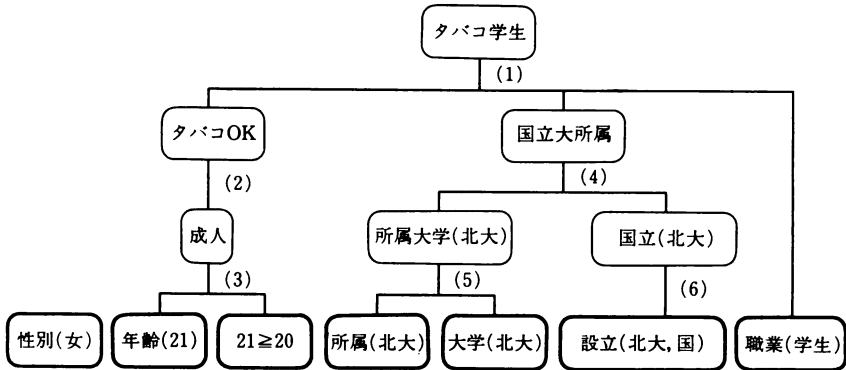


図 2 肯定例 1 の説明

et al., 1986]. ここでは、説明が EBL システムにより生成される場合を扱う。

(A) 説明の生成

説明の生成とは、訓練例と領域理論を用いて、目標概念を目標節(goal clause)とした証明木をつくることである。この証明木は、なぜ訓練例が目標概念を満たすかを説明していると考えられる。ここでは、図 2 のような説明が得られる。図中で、太線の四角が訓練例であり、かつこの数字は適用された領域理論及び目標概念を示す。目標概念に無関係な述語である「性別」が、説明に関与していないことに注意して欲しい。

(B) 一般化

図 2 の証明は、1 つの訓練例に関する具体的な説明なので、この説明を他の訓練例にも適用できるように一般化しなければならない。一般化は、領域理論により、説明が構成できるための十分条件を求めることに等しい。

一般化は、(A) で得られた説明の葉(leaf)を取り除いた部分を、説明に使われた領域理論の規則節を用いて、目標概念から後ろ向き(backward)に再構成することにより行われる。この際、規則節を構成している述語の引数間の単一化(unification)が行われる。具体例を図 3 に示す。図からわかるように、図 2 の説明が、単一化される前のもとの領域理論を用いて、再構成されている。この説明から、葉(太線の四角)が、取り除かれ、破線の上下の述語の対応する引数間で、単一化がなされる。図 3 では、変数 C と D が共に、変数 B に単一化される。

一般化された説明を図 4 に示す。ここで注意して欲しいのは、年齢の範囲設定は、

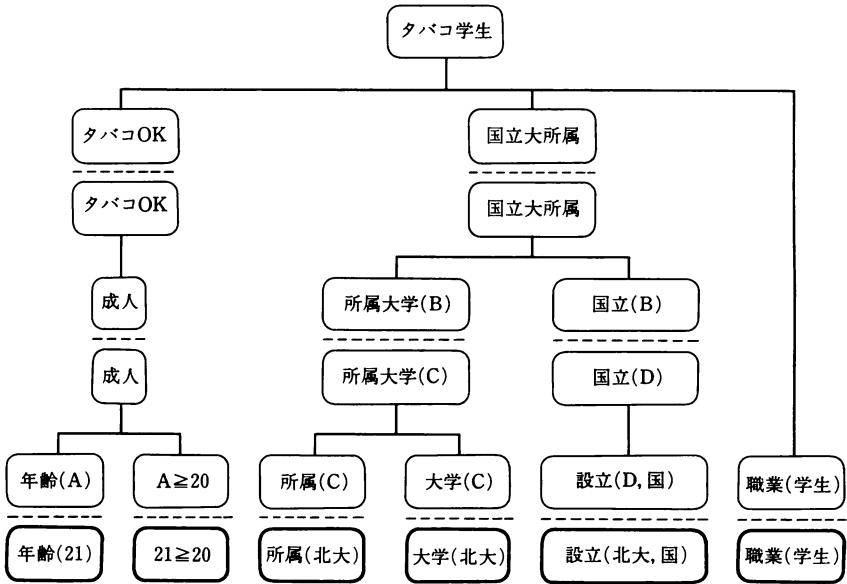


図 3 領域理論による説明の再構成

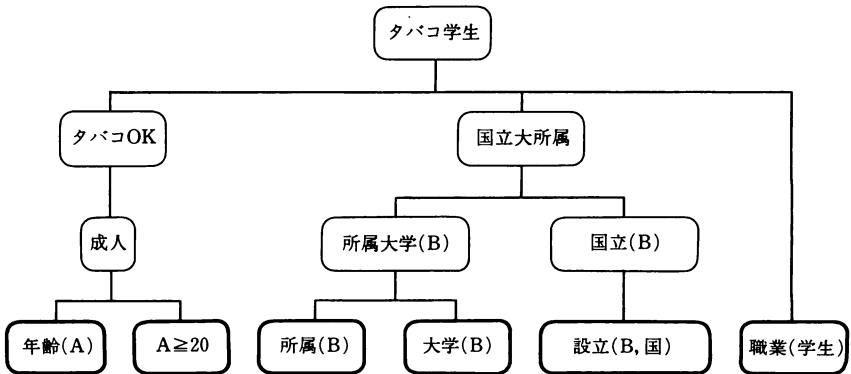


図 4 一般化された説明

成人に関する領域理論から、北大の変数化は、国立大学所属の領域理論から、それぞれ導かれていることである。これらの一般化は、SBLの探索による導き方とは、対照的である。

図4の一般化された説明の葉にあたる述語の連言が、求める概念記述である。途

中の中間仮説は、葉がすべて真であれば、領域理論より必ず証明されるので、概念記述には必要ない。よって、下記の目標概念記述が、一般化された説明の葉の連言として得られる。こうして得られた概念記述を満たす例は、必ず図2と同じ説明が構成できるので、その例は肯定例であることが判別可能になる。下に、得られた概念記述を示す。

タバコ学生 ← 年令(A) \wedge $A \geq 20$ \wedge 所属(B) \wedge 大学(B) \wedge 設立 (B, 国)
 \wedge 職業 (学生)。

この概念記述は、操作性規準を満たしているのだろうか。まず、説明の葉は、すべて単位節である。そして、この例の場合、領域理論に単位節がないので、説明の葉はすべて訓練例の単位節である。よって、説明の葉で構成された概念記述は、すべて訓練例の記述述語から成っており、操作性規準を満たしてゐる。

さらに、「訓練例の記述述語で表現される」という操作性基準により、効率向上が保障される保障はというと、実は証明木の葉だけで概念記述を作ることに依拠する。つまり、学習前では、図2の説明全体を構成しなければならないので、適用可能 (applicable) な領域理論の規則節を探索し、適用するという手続きが必要だったのが、学習後では葉の述語だけを調べればよいから、計算コストが必ず軽減され、効率が向上するわけである。ただし、この操作性規準は、1つの概念記述の学習においては有効だが、複数の概念記述の学習においては、効率がかえって低下する場合があります。問題となっている [Minton,1988; Yamada & Tsuji,1989]。なお、EBLのより詳細な説明は、[Mitchell *et al.*, 1986; DeJong & Mooney,1986] を参照されたい。

4.1で触れた説明を用いた学習の認知モデルが、EBLで実現されている。人間の教育の場合は、通常は教師が説明を与えるが、EBLでは説明は学習システム自身が生成しても良いし、教師から与えられてもかまわない。教師から入力として与えられる場合は、(A)の説明の生成は、省略される。

以上で、SBL及びEBLの概観を終わりにする。

5. 説明=バイアス

EBLにとって、説明とは何なのかという素朴な疑問がある。もちろん、国語辞典

に載っているような「説明」の説明はあるが、機械学習という観点からみて、説明の役割を考えることが重要である。そこで、本章では、機械学習あるいはEBLにとって説明とは何かという疑問に対する、筆者なりの回答を与える。機械学習の処理において、説明のはたしている役割を考えるために、ここでもう一度、EBLを詳しく見ていこう。

まず、SBLの一般化規則とEBLの一般化の關係に注目する。EBLでは、説明の一般化は、説明を構成している領域理論を用いて行われるが、この一般化は、実はSBLと同様の一般化規則を適用していると考えられる。先に挙げた「タバコを吸える国立大学生」の例では、SBLの一般化規則とEBLの間に以下のような対応が成り立つ。

- 無関係なりテラルの削除による一般化
 - SBL：条件削除規則の適用
 - EBL：説明の葉以外の削除
- 区間設定による一般化
 - SBL：区間設定規則の適用
 - EBL：説明を構成する領域理論の区間設定の制約
- 定数の変数化による一般化
 - SBL：変数化規則の適用
 - EBL：説明を構成する領域理論の変数の制約

ここで重要なのは、EBLの一般化は、SBLの一般化規則の適用と同じことを行っていると解釈できることである。その結果、前述の例からも明らかのように、EBLでもSBLでも同じ目標概念を得ることが可能であり、このことは一般的に成り立つと考えられる。

SBLの場合、一般化規則が入力として与えられるが、EBLの場合、条件削除規則以外の一般化規則（例えば、変数化規則、区間設定規則など）は、領域理論中に記述されていると考えてよい。そして、条件削除規則は、概念記述が説明に關係ある述語だけで生成されることで、適用されている。また、目標概念は、説明生成の際に、証明の目標節を与えるという重要な意味を持つが、一般化においては、領域理論と同様に一般化規則と考えてよい。よって、EBLの領域理論、目標概念は、SBLの一般化規則に対応するといえる。

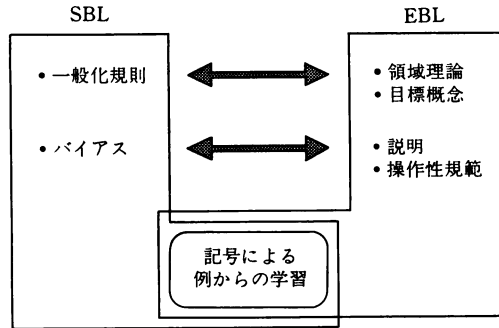


図5 記号による学習, SBLそしてEBL





しかし、SBLと同様に、EBLにおいても、領域理論と目標概念の一般化規則だけがあっても、それをどのように使って一般化を行い、概念記述を獲得すればいいのかは、わからない。そこで、領域理論や概念記述という一般化規則は、説明という経路に従って適用され、一般化が行われる。つまり、説明あるいは証明が、一般化規則の適用を強力に誘導し、一意に決定しているのである。

ところで、3章で述べたように、SBLにおいて、目標概念の探索を効率化する知識のうち訓練例以外のもは、バイアスと呼ばれる。また、EBLにおいて、一般化規則の適用を一意に決定している、つまり概念記述の探索を効率化している知識のうち、訓練例以外のもは、説明である。

以上のことから、EBLにおける説明は、SBLにおけるバイアスに相当するという結論が導かれる。さらに、一步踏み込んで、「訓練例とバイアスによる目標概念の探索」というこれまでSBLに対して用いられていた視点からEBLを見ることにより、これまでまったく別種のもだとされていたSBLとEBLは、統一的に解釈できると考えられる。すなわち、SBLもEBLも共に、訓練例と一般化規則とバイアスを用いて目標概念を生成している点ではまったく同じであり、両者の差異は本質的には、バイアスの違いによってのみ、特徴付けられる。EBLでは、そのバイアスは非常に強力で、明示的かつ特殊なものであり、説明と呼ばれ、SBLのバイアスは、弱く、暗示的でかつ一般性をもつ。以上の議論のまとめとして、式(1)と(2)をもとに、記号による例からの学習、SBLそしてEBLの3者の関係を図示したものが、図5である。

最後に、筆者は、EBL研究最大の功績は、「説明が個々の訓練例に与え得る最も強く、かつ説得力のあるバイアスの一つであることの発見である」と主張したい。説

表 4 バイアスの性質

強 度	
訓練例の量	
探 索 量	
汎 用 性	

明という概念は、昔からあったものであるが、それを機械学習の技術的な観点から捉えると、目標概念の概念記述を得るための強力なバイアスとして利用できることの発見は、EBLの本質であると考えられる。さらに、工学的な意味では、説明というバイアスが、個々の訓練例について、定理証明により自動的に生成可能なことも重要である。なお、EBLのもう1つの入力である操作性規準もバイアスに対応していると考えられる。この点については、7.3で触れる。

次章では、バイアスの強度という観点から、説明というバイアスの特性について、考えていく。

6. 「バイアスの強度」というパースペクティブ

説明をバイアスとして見た場合、大きな広がりをもつバイアスの中で、説明がどの位置を占めるのかを考えて行く。まず、バイアスをどの尺度で分類するかであるが、ここでは「強度」というパースペクティブを考える。端的に言うと、バイアスの強度とは、そのバイアスでどれだけ目標概念の探索空間が削減されるかの度合である。もちろん、大きく削減されれば、そのバイアスは強いことになる。

次に、バイアスの強度と他の特性の相関関係を考えると、表4のようになる。一般に、バイアスが強くなれば、必要な訓練例の量及び目標概念の探索量は減少するが [Utgoff, 1986]、汎用性も減少してしまうというトレードオフ (trade off) がある。これは、当然のことで、強力な制約となる知識は、領域に強く依存することが、一般に知られている。

以下に、EBLとSBLのバイアスの比較を示す。

〈EBLのバイアス＝説明〉

- ・強度：最強。

- 訓練例量：1つでよい。
- 探索量：なし。
- 汎用性：基本的に、訓練例それぞれについて、1つのバイアス（説明）が構成される。非常に領域依存性が強く、汎用性なし。そして、広範囲にわたる説明の生成には、非常にたくさんの領域理論を要する。

〈SBLのバイアス〉

- 強度：弱い。
- 訓練例量：大量に必要。
- 探索量：大量に必要。
- 汎用性：訓練例すべてに共通のバイアスを用いる。汎用性は高い。しかし、汎用性があり、かつ正しいバイアスの構築は非常に難しい。

強力なバイアスは、領域に依存するし、さらに個々の訓練例にも依存する。まさに、説明とはそういうバイアスである。SBL, EBL共に、基本的には、例からの学習に分類される。前章で述べたように、この種の学習を、「訓練例とバイアスによる目標概念の探索」と捉え、バイアスの強度という視点からみると、EBLとは最も強いバイアスの例からの学習であり、SBLは弱いバイアスの例からの学習であるという統一的な見方ができる。

7. EBL に対する素朴な疑問

よく言われていることであるが、例えば、EBLを学習と呼ぶことに対して違和感をもつというように、EBLにたいする素朴な疑問がいくつかある。本章では、これらの疑問に対し、筆者なりの回答を考えてみたい。

7.1 なぜ EBL は、「学習」らしくないのか

「EBLは、学習ではない」という主張がある[松原,1989]。筆者は、この主張には反対で、EBLは学習であると考えている。その根拠を以下に述べる。

まず、学習に対する通俗的な定義として、「未知のことが、経験により獲得される」というものが、あるのではないだろうか。（ここでは、「通俗的」を決して否定的な意味では使っていないことを断わっておく。）SBLにおいては、未知であった目標概念が、学習の結果、獲得されるのであり、この定義に合致する。ところが、EBLは、

「既知の知識が、経験によってより早く使えるようになる」だけであり、先の定義を満たさない。

しかし、人工知能研究における「機械学習」の定義は、この通俗的定義と若干異なる。最もよく知られている Simon による学習の定義[Simon,1983]を以下に示す。

「システムが、前と同じタスクまたは同じクラスから引き出されたタスクを二度目にはもっと効率よく、効果的に行えるようにすること」

この定義においては、先の通俗的定義の一部であった、「未知の知識が獲得される」という狭義の条件は見られず、「効率向上を導くような知識の変化(未知の知識の獲得も含む)」という、より広義の条件になっている。このことは、非常に重要で、もちろん未知の知識の獲得により、タスクは効率向上するのだが、既知の知識の変換によっても効率向上は可能である。EBL は、まさにその種の知識変換を行っている。筆者は別に Simon 信者ではないが、この機械学習の定義は妥当なものであると考える。そして、この定義に従えば、EBL が学習していることは、明白ではないだろうか。つまり、EBL は学習でないという意見には、先の通俗的定義がその根底にあり、なんらかの違和感を生じることが原因なのではないだろうか。

また、さらに突っ込んで、SBL においてさえも、本当に新しい知識が得られているのだろうか、という疑問がある。新しい知識とは何か。それは、今までになかった知識であろう。しかし、今までになかったとは、どういうことなのであろうか。知識ベースに今までなかったということだろうか。そうだとすると、EBL で得られた知識も、既存の知識で演出可能ではあるものの、得られた概念記述自体は、それまで知識ベースになかったものであるからおかしい。SBL でも EBL でも、あらゆる機械学習で得られる知識は、必ずそのシステムの中にその生成手続きが組み込まれている。よって、新しい知識とは、原理的にシステムがまったく考慮していなかった知識では有り得ない。

おそらく、新しい知識とは、学習システムの持っている知識からは、容易に導かれない知識、あるいはその生成過程が複雑で明確でない知識のことをいっているのではないだろうか。よって、その生成手続きが、抽象的、一般的、暗黙的であるほど、学習された知識の生成過程はたどりにくく、得られた知識は新しいものであると感じるのである。SBL における目標概念の生成手続きは、一般的、暗黙的であり、帰納学習特有の帰納的飛躍 (inductive leap) という非論理的な処理も含むのに対し、EBL のそれは、特殊で、明示的である。人間にとって、SBL により学習される知識は、その生成過程がたどり難く、EBL で得られる知識の生成過程は、説明あるいは、

演繹という形で明快に理解できる。よって、SBLでは、新しい知識が得られ、EBLでは、新しい知識は得られないという印象がもたれ、その結果、先の通俗的学習の定義から、EBLは学習でない、という主張がなされることになると思う。

7.2 なぜ EBL は学習で、コンパイラは学習ではないのか

EBLは、効率化をおこなっているに過ぎないという意味で、一種の知識コンパイラと見なされることがある。共に効率化をおこなっているにも関わらず、EBLは学習であるとは言うが、コンパイラが学習をしているとは言わない。では、その差異は何なのだろうか。

この答えも前節同様、学習の定義に深く関連していると思われる。効率化ができれば、学習であるとするならば、明らかにコンパイラもEBLも共に学習システムである。事実、EBLにおいてコンパイル処理に相当する部分である、一般化された説明から、操作可能な概念記述を生成する処理は、コンパイル技術の一種である部分計算 (partial evaluation) と等価であることが指摘されている [van Harmelen & Bundy, 1988]。しかし、松原ら[1991]も主張しているように、部分計算がEBLのすべてではないので、「EBL=部分計算」ではなく、「EBL \supset 部分計算」と考えるのが妥当である。EBLにおいて、いや、あらゆる学習において、最も重要なのは、その学習結果が、訓練例に依存することである。訓練例とは何か。それは、一種の環境の記述であると言える。つまり、訓練例によって特徴付けられた環境に対応して、効率化を図るのが、すべての学習の必須条件である。これに対し、部分計算のようなコンパイラは、訓練例あるいは環境という概念自体がなく、環境に対応して、効率化しているとは言えない。むしろ、ルールの適用シーケンスのうち、環境から独立した部分を圧縮することにより、効率化を実現している。言い替えると、考えられる環境すべてに対応して、効率化を行っていることになる。このことは、EBLにおいて、すべての環境に対応した訓練例が与えられた場合、つまり領域理論から証明され得るあらゆる定理を訓練例としてEBLを行った場合、部分計算とEBLは等価になる [van Harmelen & Bundy, 1988] ことでも明らかである。

以上のように、何らかの環境依存性がなければ、学習とは呼べず、その意味において、単なるコンパイラは学習システムではなく、反対にEBLは学習システムである。よって、その啓発的意義は認めるとしても、訓練例を軽視 (あるいは、無視) して「EBL=部分計算」を主張するBundyらの論文 [van Harmelen & Bundy, 1988] は、EBLが学習であることの本質を見据えていないものであり、そのことに

異議を唱えた松原らの主張 [松原ら, 1991] は、納得できるものである。

7.3 なぜ効率化が強調されるのか

SBL は、学習前に訓練例が肯定例か否定例かの判別ができない。つまり、学習前には問題解決の効率は無限に悪いといえる。そして、学習後には、判別が可能となるので、効率は無限に悪い状態から、有限の状態になる。よって、SBL による学習後には、効率の向上が保障されており、効率化は当然のこととして、ことさら重要視されることはない。つまり、EBL における操作性規準の概念が必要ない。あるいは、学習された任意の概念記述は必ず操作性規準を満たす。

これに対し、EBL では、学習前でも、与えられた訓練例が肯定例か否かの判断が可能であるとされている。よって、学習後の効率向上が絶対的に保障されているわけではない。事実、操作性規準の設定の仕方により、EBL による学習後、かえって効率が低下する場合もある [Minton, 1989 ; 山田ら, 1990] 効率が低下すると、EBL を使う価値がまったくないので、学習後の効率向上が実現されるか否かが、重要な問題となる。

さらに EBL では、説明のどの部分木で概念記述を生成するかで、効率向上が左右される。よって部分木の探索が生じる。この探索に対するバイアスが、操作性規準である。操作性規準により、概念記述生成に使う説明の部分木が絞り込まれる。この操作性規準にも、強度があり、例えば [Mitchell *et al.*, 1986] における「概念記述は、訓練例の表現に使われた記述言語で表現される」という操作性規準は、非常に強力なもので、説明中の部分木を一意に決定するが、反面その有効性や汎用性は低い。それに対し、[Keller, 1987] などで提案されているような、得られた概念記述で、実際に問題解決を行った結果を参考に探索する方法は、汎用性はあるが効率が悪い。

7.4 EBL は学習前に例を判別できるものなのか

学習以前に、肯定例と否定例を判別できることは、EBL にとって本質的なことなのだろうか。例えば、領域理論を用いた目標概念の証明が終了する保障がない場合、EBL といえども実質的には判別は不可能である。このような場合の典型例として、不定積分 [Mitchell *et al.*, 1986] や方程式解法 [Silver, 1986 ; 山田ら, 1988] における戦略知識の学習がある。このとき、教師により説明（証明）が与えられれば、EBL により目標概念の概念記述が得られる。このとき、SBL の場合と同じく、問題

解決の効率は、無限に悪い状態から有限によい状態に変化するので、操作性の向上は保障される。つまり、操作性規準は不要である。このとき、学習前には、訓練例の判別は不可能にも関わらず、この学習は説明という強力なバイアスを用いており、EBLであることは明らかである。よって、EBLにとって、学習前に訓練例が判別可能ということは、本質的な条件ではないと考えられる。

7.5 なぜ否定例が要らないのか

通常、EBLには、否定例が用いられない。これはなぜだろうか。逆に、SBLで、なぜ否定例が必要となるかという(必要としない場合もあるが)、正しくない一般化規則の適用の結果、過度の一般化(over-generalization)が起こった場合に、その過度に一般化された概念記述を検出するために必要なのである。ところが、EBLにおいては、領域理論が完全で正しい場合、目標概念の十分条件となる概念記述が得られることから、過度の一般化は起こり得ない。よって、領域理論が正しいという条件下で、否定例は必要ないといえる。もちろん、この条件は非常に厳しいもので、特に領域理論が大規模になると、現実問題として誤った領域理論が含まれるのは、避け難いこととなる。その場合、複数の肯定例や否定例を用いてSBLの手法をEBLと組み合わせて使うか、あるいは、誤った領域理論を検出・修正し、あくまでEBLの枠組みだけで学習を行うかの選択がある。

8. まとめ

本論文では、まずSBLとEBLを概観し、その差異を検証した。その結果、EBLの重要概念である「説明」は、SBLにおけるバイアスと見なすことが可能となった。さらに、例からの学習全体を、訓練例とバイアスを用いた目標概念の探索として捉えることにより、EBLとSBLをバイアスの強度という尺度を用いて、統一的に把握できることがわかった。

また、学習の認知モデルとしてのEBLという論点での議論が、本論文に少ないことに対し、幾分後ろめたさを感じるが、ここで展開してきたAI研究者からの学習の捉え方を他の分野からの視点で眺めることにより、なにがしか触発されるものがあるれば幸いである。

謝 辞

本論文執筆の契機を与えてくれた、諏訪基(ETL)、松原仁(ETL)両氏に心から感謝します。また、この論文は、WOL'90(Workshop On Learning)における議論に啓発されたものであり、その参加者諸氏に感謝します。最後に、論文執筆にあたり、下書き段階で不備な点を指摘していただいた佐々木寛氏と、非常に密度の高い御指摘を多数いただいた査読者諸氏に心から感謝する次第です。

文 献

- [1] Barr, A. and Feigenbaum, E. A. (Eds.) (1981): *The Handbook of Artificial Intelligence*, vol. 3, William Kaufmann. (田中・淵監訳(1983) : [人工知能ハンドブック], vol. 3, 東京, 共立出版.)
- [2] DeJong, G. and Mooney, R. (1986) : "Explanation-Based Learning: An Alternative View", *Machine Learning*, vol. 1, no. 2, pp. 145-176.
- [3] Keller, R. M. (1987) : "Defining Operationality for Explanation-Based Learning", *Proceedings of the Sixth National Conference on Artificial Intelligence*, Seattle, pp. 482-487.
- [4] 松原仁(1989) : 「AI 研究者は機械学習の研究から何を学習したのか」, 情報処理学会 知識工学と人工知能研究会-夏のワークショップ-ポジションペーパー AI-65.
- [5] 松原仁・半田剣一・秋葉澄孝(1991) : 「説明に基づく一般化≠部分計算」, 人工知能学会誌, vol. 6, no. 2, pp. 276-279.
- [6] Michalski, R. S. (1983) : "A Theory and Methodology of Inductive Learning", in Michalski, R. S. *et al.* (Eds.), *Machine Learning - An Artificial Intelligence Approach*, Palo Alto, Tioga. (電総研人工知能研究グループほか訳(1987) : 「帰納学習の理論と方法論」, 『知識獲得入門-帰納学習と応用-』, 東京, 共立出版.)
- [7] Mitchell, T. M. (1977) : "Version Spaces: An Candidate Elimination Approach to Rule Learning", *Proceedings of the Fifth International Joint Conference on Artificial Intelligence*, Cambridge, MA, pp. 305-310.
- [8] Mitchell, T. M. (1982) : "Generalization as Search", *Artificial Intelligence*, vol. 18, no. 2, pp. 203-226.
- [9] Mitchell, T. M., Utgoff, P. E. and Benerji, R. B. (1983) : "Learning by

- Experimentation: Acquiring and Refining Problem-Solving Heuristics”, in Michalski, R. S. *et al.* (Eds.), *Machine Learning – An Artificial Intelligence Approach* –, Palo Alto, Tioga. (電総研人工知能研究グループほか訳(1987):「実験による学習:問題解決ヒューリスティックスの獲得と改善」,『学習と問題解決』,東京,共立出版.)
- [10] Mitchell, T. M., Keller, R. M. and Kedar-Cabelli, R. T. (1986): “Explanation-Based Generalization: A Unifying View”, *Machine Learning*, vol. 1, no. 1, pp. 47-80.
- [11] Minton, S. (1989): “Quantitative Results Concerning the Utility of Explanation-based Learning”, *Artificial Intelligence*, vol. 42, pp. 363-391.
- [12] Silver, B. (1986): “Precondition Analysis: Learning Control Information”, in Michalski, R. S. *et al.* (Eds.), *Machine Learning – An Artificial Intelligence Approach* –, vol. II, Los Altos, Morgan Kaufmann. (電総研人工知能研究グループほか訳(1988):「前提条件解析:制御情報の学習」,『類推学習』,東京,共立出版.)
- [13] Simon, H. A. (1983): “Why Should Machines Learn?”, in Michalski, R. S. *et al.* (Eds.), *Machine Learning – An Artificial Intelligence Approach* –, Palo Alto, Tioga. (電総研人工知能研究グループほか訳(1987):「なぜ機械に学習が必要か」,『知識獲得入門』,東京,共立出版.)
- [14] Utgoff, P. E. (1986): “Shift of Bias for Inductive Concept Learning”, in R. S. Michalski *et al.* (Eds.), *Machine Learning – An Artificial Intelligence Approach* – vol. II, Los Altos, Morgan Kaufmann. (電総研人工知能研究グループほか訳(1987):「概念の帰納学習のためのバイアスの移動」,『概念と規則の学習-例からの学習-』,東京,共立出版.)
- [15] Winston, P. H. (1977): *Artificial Intelligence*, MA, Wesley. (長尾・白井訳(1980):『人工知能』,東京,培風館.)
- [16] Yamada, S. and Tsuji, S. (1989): “Selective Learning of Macro-operators with Perfect Causality”, *Proceedings of the Eleventh International Joint Conference on Artificial Intelligence*, pp. 603-608.
- [17] 山田誠二・安部憲広・辻三郎(1988):「問題解決における戦略知識学習システム:PiL-1次方程式・不等式でのケーススタディー」,人工知能学会誌, vol. 3, no. 2, pp. 206-215.
- [18] 山田誠二・辻三郎(1990):「論理プログラミング環境におけるEBLの有効性計算」,情報処理学会人工知能研究会 AI-72-7.
- [19] Van Harmelen, F. and Bundy, A. (1988): “Explanation-based generalization = partial evaluation”, *Artificial Intelligence*, vol. 36, pp. 401-412.

自己紹介

山田誠二（やまだ せいじ）

人工知能，特に機械学習，問題解決が主な研究テーマ。最近は，制約パラダイム，認知モデルなどにも興味をもつ。基本的には，社会への貢献とかいう工学研究における当為にとらわれず，自分にとって面白いことを専門分野を越えてやっていきたいと考えている。エレファントカシマシ，ダイナソー Jr.，モリッシー等のロックを愛聴。

1960年神戸生まれ，1984年大阪大学基礎工学部制御工学科卒業。

1989年同大学院基礎工学研究科博士課程修了。

現在 大阪大学産業科学研究所講師，工学博士。

受理日：1990年9月6日