

未知言語環境における帰納的学習のモデル†

赤 間 清††

本論文では、知識の構造化、仮説生成、一般化などの情報処理を人間の日常的な情報処理に必須の基礎とみなし、それらを中心に据えた人間の情報処理の全体の理論（帰納的学習システムの理論）を構築する研究の重要性を指摘する。またその研究を推進するために、システムがそれにとって未知の言語を用いた質問応答を繰り返しながら学習しなければならない設定を準備し、そのもとで動作する帰納的学習システム LS/1 を置換不変、構成的アプローチによって作成する。LS/1 はその質問応答から知識を構成的に組み立て、よりよく応答できるようになる。LS/1 の情報処理のうち知識の構造化、仮説生成、一般化などを扱うのは、有用な関係を次々に作り出す過程である。これは非常に高い自由度をもたらす可能性があるため、その制御には特別な対策が必要である。LS/1 はそのために、獲得した知識を利用して知識の構造化の組み合わせ爆発を抑制している。

1. ま え が き

人間の知的情報処理の全体は、学習ときわめて密接なつながりを持つと考えられる。しかしながらそこには、知識の管理、構造化、仮説生成、発見などの諸問題がからんでおり、知能と学習の関係をうまく記述するモデルを与えることはもとより、現在の学習研究に何を加え、どう研究していくことが人間の知的情報処理の全体の研究に発展させる意味で重要なかを展望することすら容易ではない。それは、現在の学習の研究にとって最も重要な課題の1つなのである。本論文の主要な目的は、この課題に対する新しい考え方を示し、学習研究をより広範囲に展開するための1つの枠組みを提案することである。その説明を明確化するために、本論文では、その枠組みのもとで動作する帰納的学習システム LS/1 の概要についても言及する。LS/1 は、本論文のアプローチによる研究を推進するための有力な実験台となっている。

我々の方法の第1の特徴は、人間の知的情報処理の全体と結びつけることにより、帰納的学習に対して従来よりずっと大きな役割を与えることである。すなわち本論文の帰納的学習とは、人間の日常的な活動の基礎にある、知識の構造化、仮説生成、一般化、発見などを含む知的情報処理の総称である。

我々の方法の第2の特徴は、学習に関する知見のうち、領域に依存しないレベルの知見を集積する場を与えることである。構造を発見するアルゴリズムは、そ

の構造が多くの学習対象に共有されればされるほど重要なアルゴリズムであると考えられる。達成された（みかけの）学習の性能に目を奪われる（これは領域依存のヒューリスティクスを組み込んで学習システムを構築する研究の落とし穴である）のではなく、上記の意味でより重要なものからシステムに実現していくことが必要である。

あらかじめシステムに陰に陽に領域知識を与えて学習を実現する研究の例は多い。AM や EURISKO¹⁶⁾ や BACON¹⁷⁾ などのシステムはその代表例である。しかしここでは研究者がそれらの領域知識を埋め込む作業に膨大な努力を要するだけでなく、組み入れた領域知識がシステムの知識の仮説性を制限するので、人間の基礎的な情報処理としての知識の構造化、仮説生成、一般化、発見などを扱うことが難しい。またそれらが本当に学習したり、発見したりしたと言えるのか、また、そのシステムが学習/発見にとって本質的な構造をどこに反映していると言えるのかが、きわめて不明確である。少なくともそれらは、学習に関して領域に依存しない知見を集積する枠組みは提供していない。

我々の方法の第3の特徴は、帰納的学習システムが本来扱うべき仮説空間に関して、その大きな自由度から逃避するのではなく、それを制御する問題に取り組むことである。HORN 節集合を知識表現としたモデル推論、知識利用、獲得、仮説生成などの理論^{20)~22)} は、領域に依存しない知識情報処理の理論を目指す点で本研究と共通している。また LS/1 の知識表現の主要部分は HORN 節集合の拡張版とみなすこともできる^{4), 5), 7)}。しかし HORN 節集合による知識情報処理の理論は、構造化や仮説生成や発見において、仮説空

† A Model of Inductive Learning in Unknown Language Environment by KIYOSHI AKAMA (Department of Behavioral Science, Faculty of Letters, Hokkaido University).

†† 北海道大学文学部行動科学科

間が大きくなる場合の設定を避け続けており、そのため適切な枠組みを設定できていない。

2. 学習研究の新しい課題

人間の知的情報処理の全体ときわめて密接に関係する学習を、我々は帰納的学習と呼ぶ。これは、「帰納的学習」あるいは「学習」という言葉が通常理解されているよりもずっと広範かつ強力な情報処理を意味する。知能における学習の意味を明らかにするためには、我々はまず「帰納的学習」が知能において真に果たすべき機能²⁾を正しく認識する必要がある。

我々が帰納的学習という言葉によって何を意味するかを簡単に説明する。人間は生まれたばかりの時には、他の人間と1単語の意味すら共有していない。それにもかかわらず人間は、ある言語世界の中で生活するうちにその言語を修得し、世界のいろいろな知識を獲得する。このことは、人間同士を結ぶ最も基礎的な基盤は言語ではないことを意味する。言語よりも下のレベルにあり、言語をも獲得させるような情報処理こそ、人間が持つべき基礎的で重要な知的情報処理であり、それは実は言語の獲得期だけでなく、人間の生涯の日常的な情報処理すべてを実現する基盤である、と我々は考える。本論文での帰納的学習とはそのような視点からみた人間の情報処理の総称である。これから見れば、狭義の帰納的学習、すなわち、具体例から規則を発見するアルゴリズムは、そのごく一部分にすぎない。

乳児の置かれた状況を考えてみると、任意の単語はほとんどどんな意味にも使われる可能性を持つ。また、乳児がこれから生きてゆく世界で、任意の情景が普通のように分節化され、どのように意味付けられるのかもいろいろな可能性がありうる。このように乳児が学習すべき言語や世界の知識はばく大な自由度を持つ。乳児はそれらの多様性にうまく対処する生得的な能力を持たねばならない。その生得的な能力は、例えば自然言語処理の研究における知識表現のような、具体的な単語を用いて知識を記述する方法では付与できない。乳児の持つ「知識」は(いろいろな可能性のいずれにも適用可能という意味で)もっと一般性のあるレベルのものでなければならない。学習が人間にとって不可欠となる理由がここにある。学習を実現する方法でまず考えられるのは、あらかじめ生得的な枠組みを組み込んでおき、経験によってその中に各単語を位置付ける方法である。しかしそのような方法だ

けではまだ十分な学習能力は達成できまい。乳児の対処すべき状況を観察すれば、知識の枠組み自体の発見と構築が必要であることが推測されるからである。

我々はこう考える。乳児の行う高い自由度の学習を実現するためには、少なくとも、受け取ったいろいろな情報から類似の対象、重要な構造を発見して抜き出し、一般化して仮説を作り、それらを積み上げて知識の体系を組み立てていく情報処理が必要である。我々は、言語学習や知識獲得など乳幼児期のごく日常的な情報処理は(意識下のレベルに)知識の構造化、仮説生成、一般化、発見などを必須の部分として含んでいると推測する。さらに我々は(人間の情報処理メカニズムの連続性を重視し)単に乳幼児の学習だけでなく人間の一生のすべての活動の基礎にもそれらの情報処理が存在すると仮定する。それらの情報処理、特に、仮説生成や発見などの単語は(例えば専門的な研究をする科学者の思考過程などと結びついて)高級で非日常的なものとみなされることが少なくないが、ここでは基礎的で日常的なものとして位置付けていることを強調しておく。

ここで、領域独立な理論の1つであるシャピロのMIS²²⁾と比較してみよう。MISは効率的な「帰納的学習」の方式を達成したとされるが、その効率は、人間の持つ豊かな帰納的学習をモデル化する能力を放棄し、それから見ればきわめて限定された設定を採用することによって可能になったものである。MISには、本論文の意味での帰納的学習を研究する目的に対して障害となる点が少なくとも2つある。1つは、MISが矛盾探索アルゴリズムにおいて、教師に対して際限なく知識(fact)を要求することである。もう1つは、新たな述語をシステムみずから生成して行く膨大な自由度を放棄したことである。

本論文の関心は、人間のすべての知的活動の基盤をなす情報処理としての帰納的学習システムであるが、その場合には次の2点が最も重要な点である。

(1): 知識の入力の要求が制限されているために、学習システムは矛盾の箇所を完全には特定できないままの状態に知識を蓄積しなければならない。つまりシステムの知識は仮説的知識体系である。その仮説的知識体系はどう表現され、どう管理されることが適切であるのか。

(2): 状況を的確に説明するためには、新しい述語を作ることが非常に重要である。そしてこれはシステムの情報処理の自由度を飛躍的に増大させる。これを

いかに管理するか、組み合わせ爆発を回避し、学習を加速する枠組みとは何か。

すでに行われた領域独立な研究の多くは、MISと同様に、システムが獲得する仮説の自由度を制限することによって（部分的）成功をおさめてきた。例えば、ミッチェルのバージョン・スペースの理論¹⁹⁾では、システムが持つ現在の仮説集合（過去において獲得した正の例と負の例に矛盾しない仮説全体の集合）は、全仮説の空間のなかの2つの集合（最も一般的な仮説の集合と最も特殊な仮説の集合）によって表現される。それは、新しい例の入力によって逐次的に更新される。しかしこの方法が現実的に成立するのは、明らかに小規模の仮説空間だけである。人間の持つべき仮説空間はそれとは比較にならないほど巨大であり、バージョン・スペースの理論は、（実質的には）適用できない。したがってそれは便利な要素技術とみなすべきであり、人間の全情報処理の解明には結びつく方法あるいはアイデアを提供するものではない。

では、人間の知的情報処理の全体構造へせまるための研究の手がかりとして何があるだろうか。人間の行う非常に高度な知的情報処理を計算機上で実現しようとすると、そのシステムの知的情報処理の全体構造は、利用できる時間的、空間的資源の範囲内で高度の機能実現を可能とするために満たすべき条件によって制約を受ける。人間の脳もまた現に働いている実在のシステムであるので、その知的情報処理の全体構造がそれらの条件のいくつかに束縛されていることは十分予想される。したがって、人間の知的情報処理の持つ大きな構造を把握するための有望な方法の1つは、人間に要請される基本的な知的情報処理とはどのような種類のものがあるかを考察し、それらを実現するために利用できるアルゴリズムや知識表現の時間的、空間的コストを推定し、可能な実現の方法を比較検討することである。もし、その中で空間的あるいは時間的コストのずばぬけて高いものがあるならば、それが人間という知的システムの設計の概要を決定していることは十分に予想される。

これまでのシステム作成経験から判断すれば、仮説空間の巨大な自由度をうまく扱うための情報処理は、演繹的な情報処理とは比較にならないほど空間的、時間的コストが大きい。しかもそれは人間にとって必須の情報処理であると考えられる。このように考えるとき、人間の知的情報処理の全体を解明するためには、我々は空間的、時間的コストが大きいことを恐れて、

仮説空間の巨大な自由度から目をそむけるのではなく、それをうまく制御する研究に進まざるをえない。少なくとも、それを追求して制御方法の相対的な比較を与えれば、その知見は、実際の人間の情報処理を考えるうえで大きな役割を果たすことが予想される。

3. 学習状況の設定

我々は、次のような形式化された学習状況を考える。登場するのは教師と生徒である。教師は、どんな質問にどう答えるのがよいかすべて知っている。簡単のためそれは時間 t に依存せず、対応 Γ で表現されると仮定する（質問に対する正解は任意個ありうるので写像では表現できない）。教師は生徒と質問 Q 、応答 R 、正解 A の3つのフェイズよりなる会話を繰り返す。フェイズ Q においては、教師は、対応 Γ から1つの質問文 Q_t を選んで生徒に与える。フェイズ R においては、生徒が質問文 Q_t に対して正しいと思う文の1つを応答文 R_t として教師に答える。フェイズ A においては、教師が、質問文 Q_t に対する正解文の1つ A_t を生徒に教える。 A_t は次のように決定される。 R_t が、もし対応 Γ に照らして正しい応答ならば、 A_t は R_t に一致させる。また R_t が正しい応答でないならば、 A_t は Q_t に対する正解文のなかの任意の1つの文が選択される。教師と生徒はこのような会話QRAを何回も繰り返す。生徒は毎回の会話において応答文を正解文に一致させればさせるほど高い評価が与えられる。

より形式的な表現を用いて上の記述を明確化しておこう。すべての単語の集合を Σ とすると、 Σ 上の文を Σ の単語を1個以上並べた列で定義する。 Σ 上の文全体の集合を (Σ^+) と書く。教師の持つ、質問文と正解文の対応 Γ は $(\Sigma^+) \times (\Sigma^+)$ の部分集合と等価である。対応 Γ を用いれば、質問文 Q_t に対する正解文 A_t の決定の規則は次のように書ける。

$$1: \Gamma(Q_t) \ni R_t \rightarrow A_t = R_t$$

$$2: \Gamma(Q_t) \ni R_t \rightarrow A_t \in \Gamma(Q_t)$$

対応 Γ は実際にどのような順序で学習を進めていくかは示していない。問題の提示順序の情報まで含めた質問正解の無限列を訓練列と呼ぶ。簡単な訓練列の例を図1に挙げる。この訓練列 τ_1 は、左が質問文で右が正解文である。 τ_1 において問題文に対する正解はいくとおりも想定しているが、ここでは記述の簡単のために、各問題に対して正解の例を1つだけ挙げてある。またこれは無限列の最初の部分である。

(WHAT IS DOG).....(IT IS ANIMAL)
 (SAY EXAMPLE OF ANIMAL).....(CAT)
 (DOG CAN RUN).....(YES)
 (HAWK IS BIRD).....(YES)
 (WHAT CAN BIRD).....(CAN FLY)
 (DOVE CAN FLY).....(YES)
 (WHAT IS DOVE).....(IT IS BIRD)
 (SAY EXAMPLE OF BIRD).....(DOVE)
 (WHAT IS HAWK).....(IT IS BIRD)
 (WHAT IS PIG).....(IT IS ANIMAL)
 (BIRD HAS WING).....(YES)
 (SAY EXAMPLE OF ANIMAL).....(PIG)
 (CAT CAN RUN).....(YES)
 (ANIMAL HAS LEG).....(YES)
 (WHICH IS ANIMAL : DOG OR DOVE).....(DOG)
 (WHICH IS BIRD : HAWK OR CAT).....(HAWK)

図 1 訓練列 r1

Fig. 1 An example of training sequence r1.

(TAHW SI GOD).....(TI SI LAMINA)
 (YAS ELPMAXE FO LAMINA).....(TAC)
 (GOD NAC NUR).....(SEY)
 (KWAH SI DRIB).....(SEY)
 (TAHW NAC DRIB).....(NAC YLF)
 (EVOD NAC YLF).....(SEY)
 (TAHW SI EVOD).....(TI SI DRIB)
 (YAS ELPMAXE FO DRIB).....(EVOD)
 (TAHW SI KWAH).....(TI SI DRIB)
 (TAHW SI GIP).....(TI SI LAMINA)
 (DRIB SAH GNIW).....(SEY)
 (YAS ELPMAXE FO LAMINA).....(GIP)
 (TAC NAC NUR).....(SEY)
 (LAMINA SAH GEL).....(SEY)
 (HCIHW SI LAMINA : GOD RO EVOD).....(GOD)
 (HCIHW SI DRIB : KWAH RO TAC).....(KWAH)

図 2 訓練列 r2

Fig. 2 An example of training sequence r2.

生徒は初めは対応 Γ を知らない。しかし一を聞いて十を知る能力があれば、教師との質問応答を繰り返すうちに対応 Γ の様子をしだいにうまく推測し、以前に正解を教えてもらっていない質問にも正しく答えることができるようになるだろう。我々は、そのような生徒にあたるシステムをつくることを最も粗いレベルの問題設定とする。

4. 置換不変、構成的アプローチ

我々は、訓練列 $r1$ をうまく学習するだけでなく、例えば図 2 の訓練列 $r2$ の場合にもうまく学習することをシステムに要請する。訓練列 $r2$ は我々にとって理解しにくい、実は、 $r1$ の各単語に現れるアルファベットの順序を単語ごとに逆転して得られる。したがって、既存の知識を仮定しなければ $r1$ と $r2$ は等価であると考えることができる。その意味で等価な訓練

列に対する学習過程（学習の結果得られた、質問 Q_t 、応答 R_t 、正解 A_t の組 (Q_t, R_t, A_t) の無限列）が互に対応したものであるとき、システムは置換不変性を持つと言う。

置換不変性を明確に述べる。単語の集合を Σ 、 Σ 上の訓練列全体の集合を T 、 Σ 上の学習過程全体の集合を L とする。 Σ 上の任意の置換 p は、 T 上の置換と L 上の置換を引き起こす。それらも p で表すことにする。システムの決める T から L への写像を S とする。システムが置換不変であるとは、任意の訓練列 τ と任意の置換 p に対して、

$$p(S(\tau)) = S(p(\tau))$$

が成り立つことである。

言語では、各単語がどのような発音やスペルを持つかに（大幅な）任意性がある。人間は、他人と 1 単語も共有していない誕生直後の状態から出発して、しだいに自分の知識体系を組み立てていく。もし英語とよく似た言語を話す架空の世界があって、英語の世界で *some* と言うところを *of*、また、*of* と言うところを *some* と言うだけの違いしかなければ、その架空の世界における人間の生涯の行動は、やはり、*some* と *of* の逆転以外は実際の英語の世界となんら変わらないだろう。これは置換不変性に対応している。

システムに課された置換不変性はシステム作成に際して厳しい制約となる。置換不変性により、少なくとも単語レベルでシステムに知識を入れておくことは無効になり、与えられた質問応答 (QRA) を素材にして、一般的な操作だけで知識を組み立てていく構成的なやり方をすることが、十分な適応能力を確保する前提としてどうしても必要になる。置換不変性を尊重して、注意深く、何がどの程度の一般性を有するものかを吟味し、極力 *ad hoc* 性を排除するように努めながら構成的なシステムを作成し、理論を改善していく研究方法を置換不変、構成的アプローチと呼ぶことにする。学習とは何か、意味とは、文法とは、…などの根本的な問題をより深く突き詰めて考察するために、このアプローチは大きな役割を果たす可能性がある。知識を詰め込んで安易に人間に「似せる」わけにはいかないからである。

5. 帰納的学習システムの基本原理

最初に考えなくてはならないことは、一を聞いて十を知るための基本メカニズムである。我々は、次のようなアイデアを採用する。システムがある時点で

$\Gamma \ni ((\text{WHAT IS DOG}), (\text{IT IS ANIMAL}))$
 $\Gamma \ni ((\text{WHAT IS SALMON}), (\text{IT IS FISH}))$
 $\Gamma \ni ((\text{SAY EXAMPLE OF ANIMAL}), (\text{DOG}))$
 $\Gamma \ni ((\text{SAY EXAMPLE OF BIRD}), (\text{EAGLE}))$

という情報を得ていると仮定しよう。これは次のように書き直せる。

$\Gamma \supset \{((\text{WHAT IS } \$X), (\text{IT IS } \$Y))$
 $\quad | (\$X, \$Y) \in S1\}$
 $\Gamma \supset \{((\text{SAY EXAMPLE OF } \$P), (\$Q))$
 $\quad | (\$P, \$Q) \in S2\}$

$S1 \ni ((\text{DOG}), (\text{ANIMAL}))$
 $S1 \ni ((\text{SALMON}), (\text{FISH}))$
 $S2 \ni ((\text{ANIMAL}), (\text{DOG}))$
 $S2 \ni ((\text{BIRD}), (\text{EAGLE}))$

ここで $S1$ と $S2$ の間の関係が、なんらかの根拠 (例えば, (DOG) と (ANIMAL) のペアが $S1$ と $S2$ で逆順になって入っている) に基づいて、

$S1 \ni (\$X, \$Y) \longleftrightarrow S2 \ni (\$Y, \$X)$

と推測されたとする。この推測は $S2$ から $S1$ へ、また、 $S1$ から $S2$ へ、新しい元を供給する。それらは、それぞれ、

$((\text{EAGLE}), (\text{BIRD}))$ into $S1$
 $((\text{FISH}), (\text{SALMON}))$ into $S2$

である。これは Γ に対して、

$\Gamma \ni ((\text{WHAT IS EAGLE}), (\text{IT IS BIRD}))$
 $\Gamma \ni ((\text{SAY EXAMPLE OF FISH}), (\text{SALMON}))$

という2つの推測を生み出し、

(WHAT IS EAGLE)
 $(\text{SAY EXAMPLE OF FISH})$

という2つの新たな質問にうまく答えうる可能性をもたらす。

これらのアイデアを核として、置換不変、構成的アプローチにより、一般的かつ具体的なシステムに発展させたのが帰納的学習システム LS/1 である。LS/1 はよりよい応答をするために、各回の質問応答 (QRA) から得た情報をもとにして仮説的知識体系を逐次的に作り、未知の問題に対する答えをよりの確に推測し、それに答える。

ここでシステムの一般性について特に注意したい。我々は LS/1 によって直接的にある特定の学習過程を模擬しようとするわけではない。システムの説明にはいろいろな例が用いられるが、それらは分かりやすくするためにたまたま選ばれたものである。システムはそれが扱う単語 (例えば DOG , ANIMAL など) に

よって人間が連想する意味内容のレベルとはまったく独立なレベルの原理で作られる。

そのようにして組み立てられたシステムに特定の「意味ある」訓練列を与えた場合、十分うまく扱える可能性はありうるのだろうか。我々はその可能性は十分にあると推測する。次節以降の記述は、この可能性を実現するために我々が提案する有望な糸口である。少なくとも我々は、その可能性の範囲をはっきりと見極めることこそが、学習と知能を研究していくうえで最も重要な課題であると確信する。

6. LS/1 の核となる情報処理の概要

(Σ^+) の n 個の直積の部分集合を、単に、 n 項関係、または、RELATION (以下 REL と略記する) と呼ぶことにする。また、REL の要素を TUPLE (以下 TPL と略記する) と呼ぶ。例えば、学習中の生徒が、それまでの質問応答によって、質問と正解の関係になりうる文のペアの集合

$((\text{WHAT IS CAT}), (\text{IT IS ANIMAL}))$
 $((\text{DOG CAN RUN}), (\text{YES}))$
 $((\text{WHAT IS CAR}), (\text{IT IS VEHICLE}))$

を得たとする。これは1つの REL (2項関係) であり、質問正解ペアの1つ1つが TPL である。この REL から、例えば、

$((\text{WHAT IS } \$X), (\text{IT IS } \$Y))$

の形を持つ TPL を取り出し、変数 $\$X$, $\$Y$ に入るべき単語列の組を列挙すると、

$((\text{CAT}), (\text{ANIMAL}))$
 $((\text{CAR}), (\text{VEHICLE}))$

という新しい REL が得られる。このように任意の REL から別の REL を生み出すものを一般に文脈と呼ぶことにする。

LS/1 は、すでに得られた REL から新しい有用な REL を生成する可能性のある文脈を見つけ出す。その1つの方法はマッチングを用いる方法^{6),7),10)} である。例えば REL の2つの TPL

$\text{TPL } 1 = ((\text{WHAT IS DOG}),$
 $\quad (\text{IT IS ANIMAL}))$

$\text{TPL } 2 = ((\text{WHAT IS CAR}),$
 $\quad (\text{IT IS VEHICLE}))$

から、マッチングにより、文脈

$\text{CTX } 0 = ((\text{WHAT IS } \$1),$
 $\quad (\text{IT IS } \$2)) \rightarrow ((\$1), (\$2))$

が得られる。

((DOG), (ANIMAL))
 ((CAT), (ANIMAL))
 ((CAR), (VEHICLE))
 ((DUCK), (BIRD))
 ((HAWK), (BIRD))

図 3 RELATION の例
 Fig. 3 A relation.

REL 1	REL 2	
((DOG), (RUN))	((RUN), (DOG))	
((CAT), (RUN))	((RUN), (CAT))	
((SALMON), (SWIM))	((SWIM), (SALMON))	
REL 3	REL 4	
((DOG), (ANIMAL))	((ANIMAL), (RUN))	
((CAT), (ANIMAL))	((FISH), (SWIM))	
((SALMON), (FISH))		
REL 5	REL 6	REL 7
((DOG), (RUN))	((DOG), (ANIMAL))	((RUN), (ANIMAL))
((HAWK), (FLY))	((EAGLE), (BIRD))	((FLY), (BIRD))

図 4 RELATION の例 (REL1-REL 7)
 Fig. 4 Examples of relations (REL1-REL 7).

LS/1 は REL から射影や逆像によっていろいろな集合を作り出す。例えば図 3 の REL から射影により
 集合 1 = {DOG, CAT, CAR, DUCK, HAWK}
 集合 2 = {ANIMAL, VEHICLE, BIRD}
 が得られる。また、集合 2 の要素の逆像により
 ANIMAL の逆像 = {DOG, CAT}
 VEHICLE の逆像 = {CAR}
 BIRD の逆像 = {DUCK, HAWK}
 が得られる。

これらは、上記の、文脈と REL (n 項関係) による扱いの特別な場合として位置付けることができる。例えば、図 3 で、集合 1 を得る射影には、文脈

CTX3 = ((\\$1), (\\$2)) → ((\\$1))

が対応する。また ANIMAL の逆像を得るには、文脈

CTX4 = ((\\$1), (ANIMAL)) → ((\\$1))

を用いればよい。

LS/1 は、REL を変形して新しい REL を作り、そのなかのいくつかの REL を同一視することによって一般化を行う。ここでは REL のあいだの関係として置換や合成を採用した例をとりあげる。例えば図 4 で、REL 1 は REL 2 から (TPL の成分) 置換によって得られる。また REL 1 は、REL 3 と REL 4 の合成である。学習中に得られる REL は「不完全なもの」であり、厳密にこれらの関係が成り立つことはまれである。実際の学習の過程では、REL どうしの関係は、含まれるいくつかの TPL どうしの関係から推測される。例えば、図 4 の 3 つの TPL,

((DOG), (RUN)) in REL 5

((DOG), (ANIMAL)) in REL 6

((RUN), (ANIMAL)) in REL 7

は、合成関係

REL 5 = (EQL REL 6) (REV REL 7)

(これは、REL 6 と、REL 7 の逆転との合成が REL 5 に等しいという意味である) を推測する根拠の 1 つである。これにより REL 5 の中に

((EAGLE), (FLY))

も入っていることが推測される。推測の根拠となる TRL の数は多いほどよい。またこの推測は (5 節の原理に基づいて) 新問題への応答を可能にする。

すべての一般化のアルゴリズムには、一般化しすぎて誤りを引き起こす可能性が常に存在する。過剰な一般化の存在は、LS/1 においては、システムが誤った応答 R を生成することによって明らかになる。その結果システムは、負の例を得る。

過剰な一般化が実際のルールによるものかを、負の例 1 つから推測するのはきわめて困難である。シャピロの MIS はこの場合、教師に対して必要ならばいくらかでも多くの質問に答えることを要求する。この方法は大きい仮説空間を扱う場合不相当である。

LS/1 では、負の例からの学習を 2 種類採用している。1 つは負の例を知識表現の各ルール部分に蓄えておいてそれを一般化する方法^{2), 6), 7)} である。この方法により、基本的には LS/1 が同じ誤りを 2 度繰り返すことはない。もう 1 つは、LS/1 の各ルールに付加された確信度を利用するものである。LS/1 は、負の例が得られるごとに、それを生成するのに使われる各ルールの確信度を減少¹⁶⁾ させている。確信度の変化は最終的には、応答生成に最良優先探索アルゴリズム^{8), 12)} を採用することによって、システムの応答に反映される。最良優先探索アルゴリズムは、質問 Q_t が与えられると、各ルールとそれらの確信度を総合して、 Q_t の答えに最もふさわしいと思われる応答文を生成するものである。

7. 帰納的学習の高自由度とその制御

LS/1 の知識形成の基本は、文脈を用いて有用な REL を次々に提案し、別の REL と同一視する仮説を作り出す過程である。これは構造化、仮説生成、発見などに対応する情報処理を実現するために必須の過程である。広い範囲の REL を対象として、重要な REL を作り出し、それらの関係を適切に扱うことは、

帰納的学習システムにとって本質的な特徴である。しかしここには重大な問題がある。文脈や REL は無数に存在するが、知識をうまく構築したり、その結果新しい質問に対する正しい推測を導くために有効に利用できるものはそのうちのほんの一部だけである。重要な REL の発見のための探索は組み合わせ爆発を引き起こす危険性が非常に高い。システムの学習能力は、有効な文脈や REL や仮説をうまく選択する方法やそれを可能とする枠組みに大きく依存する。

あらかじめシステムの扱う領域を限定して、領域固有の知識を埋め込むことによって探索範囲を限定する方法は、そのような組み合わせ爆発を回避するために現在知られるほぼ唯一の方法^{17),18)}である。しかし我々は、領域固有知識を利用する方法を採用しない。領域固有知識は、基本的には知識を作るシステムの研究であるべきはずの学習の研究を、実質的には知識を使うシステムの研究に置き換えてしまうからである。置換不変性の要請はそのような落とし穴を避ける目的で導入されたものである。LS/1 で利用するための組み合わせ爆発回避法は、少なくともシステムに課せられた置換不変性の条件を損わないような一般性を持たねばならない。

領域固有の知識を利用する方法に代わる、より一般的な組み合わせ爆発回避の方法ははたして存在するのだろうか。過去においてそのような問題設定はほとんどなされたことはなく、現在それを目指している学習の研究も見当たらない。しかし我々は、その可能性を追求してシステムあるいは理論を構築していくことが、学習や知能の研究にとって必須であると主張する。

領域独立性を保ったまま、REL の生成を含む情報処理の組み合わせ爆発を回避する方法を開発するためには、獲得から利用までのいろいろな情報処理の巧妙で柔軟な連係の可能性を追究⁹⁾することが必要であろう。以下では、LS/1 で試みられている方法のうちいくつか簡単に言及する。

生成された REL のうちからより有効なものを選び出すために LS/1 は

- REL の TPL の数が多いほど重要
- 応答生成^{9),12)}に使われる回数が多いほど重要
- 他の知識との関連が強く推定できるほど重要

などのヒューリスティックスを用いている。本論文では、このうち最後のヒューリスティックスの重要性を特に強調したい。このヒューリスティックスは、他の

知識との関連としていろいろなものを想定することによって、きわめて広範囲の応用可能性を持つのである。LS/1 の学習能力はいろいろな点で改善されつつあるが、そのかなりの部分が、他の知識との有用な関連を定式化し、それを効果的に処理するアルゴリズムを作ることによって達成されている¹⁶⁾。

重要な文脈の発見の場合、LS/1 は、最初は単に2つの TPL を任意に選んでマッチング¹⁰⁾し、その結果得たマッチングの良さを基準にして知識を構築するために使う文脈を選択する。しかし、知識がたまってくるとそのような初歩的なやり方からだんだんうまいやり方に移行し、より重要度の高いと思われる文脈をより少ない手間で見つけることが可能になる。例えば6節の文脈発見の例で、もし DOG や ANIMAL が重要な単語であると LS/1 がすでに推測していたり、あるいはさらに強く、

((DOG), (ANIMAL))

の属する REL は重要であると信じている場合には、TPL 1 だけから文脈 CTX 0 を作り出すこともできる。

LS/1 は、単一種の知識ではなく、いろいろな種類の知識を作る。幹となる知識は、 n 項 REL やそれらの相互関係、1 項 REL (集合) やそれらの相互関係、REL と集合の関係などであるが、そのほかに、どの単語がどこに現れるかを示す単語帳や連想リスト、文脈になりやすい単語と重要な REL の TPL に現れる単語とを区別する知識、REL や TPL への確信度など少しレベルの違う知識も作成される⁹⁾。

詳細は割愛するが、これらの知識も、新たな REL を効果的に選び出していくために利用される。ここで強調したいことは、これらの知識そのものがシステムの作成した知識だということである。そこでは、システムが獲得した知識で新たな知識獲得を加速し、その知識がさらに効果的に次の知識獲得を導いていく^{14),16)}という情報処理(獲得知識による知識獲得の加速化)が目指されている。これは、領域依存の知識を利用した学習が主にシステム作成者の埋め込んだヒューリスティックスを使用しているのとの大きなちがいである。このために我々の設定は、「システムが独力で獲得できるものはいったいどこまでなのか」という学習と知能の根本の問題に着実に接近する場を与えている。

8. む す び

人間の日常的な活動を理解するためには、それらの

基礎に、知識の構造化、仮説生成、一般化、発見などの情報処理が存在すると仮定しなければならない。そのような視点から見た知的情報処理を総称して帰納的学習と呼ぶ。帰納的学習の実現は演繹的な情報処理とは比較にならないほど困難なので、(それらをうまく実現するために)人間の知的情報処理の概略はそれらの情報処理にとって都合のいい形に決定されている可能性が高いと推測される。したがって人間の情報処理全体の理論を目指すためには、それらの情報処理を中心に据えたモデル(帰納的学習システム)を作成することが有効と考えられる。

我々は、形式化された学習の設定のもとで、置換不変、構成的アプローチによって帰納的学習システム LS/1 を構成した。それは未知の言語を用いた質問応答により、知識を獲得し、よりよく応答できるようになる。人間の日常的な活動を可能にする基本的で必須の情報処理としての知識の構造化、仮説生成、一般化、発見などを考察する場合は、LS/1 の枠組みの中で有用な REL を次々に作り出す過程を扱うことによって得られる。この過程は生成される知識に高度の多様性をもたらす可能性があるため、その制御には特別の対策が必要である。LS/1 はそのために、獲得した各種の知識を利用して知識の構造化の組み合わせ爆発を抑制している。

誌面の制約のために本論文は、学習の設定(学習状況や置換不変性)や学習の基本原理解や帰納的学習システムの最も特徴的な部分(RELの生成とその自由度への対策)の概要に主眼をおいて記述した。その背後には基礎となる多くの理論(例えば、本論文で与えた学習の設定や置換不変性の必要性の根拠⁹⁾をなす理論、知識表現の方法¹⁾とその背景となる数学的理論^{4),5)}など)やアルゴリズム(各部分の知識獲得^{10),11),13)}と利用^{8),10),12)}のアルゴリズム)が存在する。それらは別の論文で詳細に議論する予定である。

知能と学習をさらに深く研究することを考えると、そのための基礎的考察も、研究の枠組みも、まだまだ不十分である。本論文はそのために、帰納的学習システムの理論の構築という長期的課題の重要性を初めて明らかにし、LS/1 によってその課題へ接近する具体的な糸口を与えた。帰納的学習システムの理論を完成するためにはさらに非常に多くの研究を積み重ねる必要がある。それらの中で、特に LS/1 をさらに発展させるための(本論文が記述したような大きなレベルの)問題としては、(1)獲得知識による知識獲得の

加速化のさらなる追求、(2)知識の構造化における誤り回復への本格的な対処、(3)この枠組みの中への文法の位置付け、(4)視覚など言語以外の入力への導入¹⁵⁾などがある。

参 考 文 献

- 1) 赤間 清, 市川惇信: 学習システムのための記号列集合の表現, 電子通信学会論文誌, Vol. 61-D, No. 9, pp. 649-656 (1978).
- 2) Akama, K. and Ichikawa, A.: A Basic Model for Learning Systems, *Proceedings of 6th IJCAI*, pp. 4-5 (1979).
- 3) 赤間 清, 市川惇信: 知能のモデル化のためのシステム設計問題(3)—知能システムを把える2つの視点, 電子通信学会技術研究報告, PRL 79-114, pp. 35-41 (1980).
- 4) 赤間 清: ベキ集合を変数とする変数に関するある種の連立方程式とその最小解, *HBSR M(S)*, No. 2, p. 8 (1983).
- 5) 赤間 清: 連立方程式に基づくネットワークを用いた表現のシステムとその重要なサブクラス, *HBSR M(S)*, No. 3, p. 7 (1983).
- 6) 赤間 清: 帰納的学習を行なうシステムの初歩的なモデル, *HBSR M(S)*, No. 7, p. 29 (1984).
- 7) 赤間 清: 帰納的学習システム LS/0 を実現するプログラムの概要, *HBSR M(S)*, No. 8, p. 94 (1985).
- 8) 赤間 清: 帰納的学習システムの最良応答探索, 情報処理学会, 知識工学と人工知能研究会資料, 41-12, pp. 89-96 (1985).
- 9) 赤間 清: 未知言語環境における帰納的学習のモデル, シンポジウム: 学習の諸問題 報告論文集, pp. 38-55 (1986).
- 10) 赤間 清: 文字列領域における一般化と統一化のアルゴリズム, 情報処理学会, 知識工学と人工知能研究会資料, 45-6, pp. 41-48 (1986).
- 11) 赤間 清, 滝川雅巳: データベースの帰納的構成—関係管理システム—, シンポジウム: 学習の諸問題報告論文集, pp. 65-80 (1986).
- 12) 赤間 清: 最良優先探索 PROLOG, 情報処理学会, 知識工学と人工知能研究会資料, 47-8, pp. 57-64 (1986).
- 13) 赤間 清, 小笠原秀美: 概念管理システム, 情報処理学会, 知識工学と人工知能研究会資料, 47-9, pp. 65-72 (1986).
- 14) 赤間 清: 帰納的学習システム LS/1 による翻訳の学習, 情報処理学会, 知識工学と人工知能研究会資料, 48-5, pp. 33-40 (1986).
- 15) 赤間 清: 学習研究の期待・課題・将来, 計測と制御, Vol. 25, No. 9, pp. 810-811 (1986).
- 16) 赤間 清: 翻訳知識の帰納的学習, 日本ソフトウェア科学会第3回大会, B-6-2, pp. 205-208 (1986).

- 17) Langley, P., Bradshaw, G. and Simon, H. A.: BACON. 5: The Discovery of Conservation Laws, *Proceedings of the Seventh IJCAI*, Vancouver, pp. 121-126 (1981).
- 18) Lenat, D.: The Role of Heuristics in Learning by Discovery: Three Case Studies, *Machine Learning*, Michalsky, Carbonell and Mitchell (eds.), p. 572, Tioga, Palo Alto (1982).
- 19) Mitchell, T. M.: Version Spaces: A Candidate Elimination Approach to Rule Learning, *Proc. of Fifth IJCAI*, Cambridge, Mass., pp. 305-310 (1977).
- 20) Miyachi, T., Kunifuji, S., Kitakami, H., Furukawa, K., Takeuchi, A. and Yokota, H.: A Knowledge Assimilation Method for Logic Databases, *New Generation Computing*, Vol. 2, No. 4, pp. 385-404 (1984).
- 21) Poole, D., Goebel, R. and Aleliunas, R.: Theorist: A Logical Reasoning System for Defaults and Diagnosis, *Knowledge Representation*, Cercone, N. J. and McCalla, G. (eds.), Springer-Verlag, New York (1986).
- 22) Shapiro, E.: Inductive Inference of Theories from Facts, Technical Report, Yale University, pp. 1-50 (1981).
(昭和 61 年 2 月 2 日受付)
(昭和 61 年 11 月 5 日採録)



赤間 清 (正会員)

昭和 24 年生。昭和 48 年東京工業大学制御工学科卒業。昭和 50 年同大学院修士課程修了。昭和 54 年同博士課程退学。同年東京工業大学制御工学科助手。昭和 56 年北海道大学文学部行動科学科講師。現在に至る。人工知能に興味を持つ。とくに昭和 50 年より一貫して帰納的学習システムを研究し、知能を把える新たな枠組みの構築を目指している。現在、人工知能学会、日本ソフトウェア科学会、日本認知科学会などの会員。