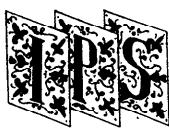


解 説**ア ナ ロ ジ 一****6. 人 工 知 能 と 類 推[†]**沼 尾 正 行^{††} 佐 藤 理 史^{†††} 有 馬 淳^{††††}**1. は じ め に**

本特集では、心理学、論理学、言語学などの多様な見地から、「アナロジー」および、それを用いた推論である「類推」について論じてきた。計算機による情報処理、特に人工知能研究では、従来から多くの推論、学習手法が研究されている。そこで本稿では、特集を締めくくる意味で、人工知能における各種手法と類推との関係について考えることにする。

まず、2. では有馬が、論理の立場に立って、演繹、帰納、アブダクションと類推の関係を検討し、それらを位置付ける。人工知能、特にエキスパートシステムや学習システムにおいては、「説明」が重要な役割を果たしている。実は、類推においても「説明」は影の立役者であり、3. で沼尾がそれについて解説を行う。4. では佐藤が、近年脚光を浴びてきた事例に基づくアプローチと類推の関係を検討する。5. では、以上の議論をまとめ、人工知能における類推研究のマップを示す。

**2. 演繹、帰納、アブダクションと
類推—類推の論理的位置**

演繹は厳格さだけが取り得の（石頭！）退屈ジジイ。

帰納は浪費ぐせある世間知らずの学者さん。

アブダクションは言い訳好きの尻軽娘。

類推はものまね好きの万年青年。

どいつもこいつも一人の頭を悩ませやがる。

2.1 推論の三分法と類推

演繹、帰納、アブダクション、類推はそれぞれ非常に古くから人間の思考形態を表すものとして多くの研究者の関心を引きつけてきた。これらの推論は互いに深い関係があると考えられ、これまで形式的な立場からいくつかの比較が行われている。ここでは、これらの考え方を簡単に紹介し、類推とそれらの間の関係を議論する。

Peirce は推論の三分法⁹⁾として演繹、帰納、アブダクションの違いを以下に述べるように表現している。類推もこれにならい加えて比較してみよう*。図-1 で説明する。演繹では大前提：「人間はだれでも死ぬ運命にある」という規則と小前提：「Socrates は人間だ」という事実から、結論：「Socrates は死ぬ運命にある」を導く。帰納はこの小前提と結論から逆に大前提となる規則を見い出し、アブダクションはこの大前提となる規則と結論から逆に小前提を推測するものである。類推はこれらに比べると対象（ターゲットと呼ばれる）外の事物（ベースまたはソースと呼ばれる）が関係してくる点で少々持って回ったようなものになる。その推論は表面上は「Socrates も Aristotle も同じ人間だ」（あるいは、「Socrates も Aristotle も似ている」といった類似性に関する前提と、小前提「Socrates は死すべき運命にある（あった）」から類推結論：「Aristotle も死すべき運命にある」を引き出す。

すなわち、インフォーマルには、「帰納」は観測事実の間のより一般的な関係を見い出す思考形態を、「アブダクション」は観測事実から既知の

* Artificial Intelligence and Analogical Reasoning by Masayuki NUMAO (Department of Computer Science, Tokyo Institute of Technology), Satoshi SATO (School of Information Science, Japan Advanced Institute of Science and Technology, Hokuriku) and Jun ARIMA (International Institute for Advanced Study of Social Information Science, Fujitsu Laboratories Ltd.)

† 東京工業大学工学部情報工学科

†† 北陸先端科学技術大学院大学情報科学研究科

††† (株)富士通研究所国際情報社会科学研究所

* Peirce の推論の三分法では、大前提、小前提などのインフォーマルな言葉を使い説明しているため、帰納、アブダクションの違いを含めて曖昧さが生じているがここでは目をつぶっていただきたい。Peirce 自身のアブダクションの定義は形式的でなく、近年多くの解釈を生み混乱している。

演繹	
大前提 : $\forall x. (Human(x) \supseteq Motal(x))$	
小前提 : $Human(Socrates)$	(Ded)
結論 : $Motal(Socrates)$	
帰納	
小前提 : $Human(Socrates)$	
結論 : $Motal(Socrates)$	(Ind)
大前提 : $\forall x. (Human(x) \supseteq Motal(x))$	
アブダクション	
大前提 : $\forall x. (Human(x) \supseteq Motal(x))$	
結論 : $Motal(Socrates)$	(Abd)
小前提 : $Human(Socrates)$	
類推	
類似前提 : $Human(Socrates) \wedge Human(Aristotle)$	
小前提 : $Motal(Socrates)$	
類推結論 : $Motal(Aristotle)$	(Anl)

図-1 Peirce の推論の三分法と類推

因果的な規則や物理的な法則を用いてその原因を推定する思考形態を指している。これに対し「類推」は、少なくとも表面的には、未知の事例に対し、類似する既知の事例における解や性質をあてはめる思考形態を指している。

さて、ここまで繰り返し「類推は…表面的には」と言ってきたのは、このスキーマで完全に類推を表しているとは言えないからである。われわれが通常使う類推の表現には現れていないが、前提としてある隠れた知識を使ってわれわれは類推を行っていることが一般に認められている。しかし、この隠れた前提が具体的にどんなものなのについては現在も係争中である（文献 3）参照）。

2.2 学習の三角形

三分法と少し違った側面から Mostow⁷⁾ は学習の三角形で帰納、類推、演繹（原文では “Induction, Analogy, Compilation”）の関係を図-2 のように表している⁸⁾。

この関係は類推のメカニズムに関する興味深い示唆を含んでいる。それは、「類推はなんらかの知識をベース（既知の事例）からターゲット（未

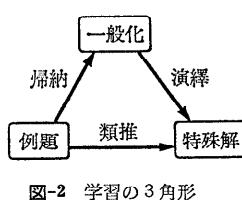


図-2 学習の3角形

* この文献に関する情報の提供、訳語については、山村雅幸氏（東工大）、石崎俊氏（慶應大）のご助力を多とする。ここに感謝を表したい。

知の事例）へ“直接”投射することで行われる推論方法である」ともみえるが、「類推はベースからいったん帰納的に一般ルールを得た後、演繹的にターゲットに関する知識を得る推論方法である」⁹⁾とも考えられるということである。先の Peirce もこれに対応する二通りのスキーマが考えられることを（非形式的にだが）表している。ただし、後者の考え方を字づらざり“一般化”して考えないように強く注意を促したい。というのは、これまでの議論では“数”的パラメータが落ちているからである。類推がいったん一般化した知識から得られているにせよ（そうでないにせよ）この「帰納」は一般的の『帰納』とかなり異質のものである。『帰納』はよく知られているとおり、有用な推測を得るまで非常に多くの例を必要とする。ところが、興味深いことに類推では多くの場合、たった一例（ベース）で有用な結果を得る。これは明らかに先に指摘した類推の隠れた知識の利用によるものと考えられる。

これらの関係に関するこれ以上の詳しい議論は本稿の域を越えると思われる（文献 1), 2) に譲り、表-1 に簡単な比較表を示すことにどめる。

2.3 類推と他の推論の関係——まとめ

この章では類推と他の推論の関係をごく簡単に紹介した。各推論についてもう少し詳しく知りたい方には、（演繹はよいですね？）帰納は文献 6) アブダクションは文献 4), 類推はもちろん（？）この特集号から始められるのはいかがだろうか。

なお、類推そのものとの比較の観点からこの章では述べてきたが、類推をメタな観点から補助的に他の推論に使う多くの研究がある。過去に行なった問題解決をもとに類似の問題に対する問題解決を高速化する研究、たとえば演繹系における定理証明に使ったものとして文献 5), 10), 11) や、帰納推論の分野では過去のプログラムを使って新しいプログラムを生成する研究^{8), 12)}などがある。興味に応じて調べていただければ幸いである。

* 三分法の例だと、

小前提 : $Human(Socrates)$
結論 : $Motal(Socrates)$

(Ind)

(大前提) : $\forall x. (Human(x) \supseteq Motal(x))$

小前提 : $Human(Aristotle)$

(Ded)

類推結論 : $Motal(Aristotle)$

(Anl')

と類推のスキーマを分解して考えれば、類推=帰納+演繹である。

表-1 比較表

	演繹	帰納	アブダクション	類推
演繹的か 非演繹的か	演繹的	非演繹的	非演繹的	一般的に 非演繹的
使用する例の数	0個	(理論的に) 無限個	0個	(基本的に) 1個
背景知識の 使用的度合	極端に 強い	極端に 弱い	強い	強い
適用される領域	定義しやすい	(定義しにくい)	(定義しやすい)	定義しにくい

3. 類推における「説明」の役割

エキスパートシステムや、コンピュータ教育システムにおいては、ユーザに推論過程を示すための説明機能が重要である。さらに機械学習において、説明により学習が効率化されることが明らかとなり、「説明に基づく学習」と呼ばれる手法が生み出された。類推において効率的に正確な結果を得るためにも、説明を活用することが重要である*。

3.1 説明に基づく学習

人間がスキーを習う場合を考えてみよう。スキー学校に通わず、自己流で練習しても上達するのは難しい。スキー学校に通って教師からスキー理論の説明を受け、それにしたがって練習するのが早道である。数学の問題の解き方を学ぶ場合でも、やみくもに問題を解こうとするよりは、代表的な問題の解き方を説明してもらったほうがよい。以上の考え方により、コンピュータの学習機構において説明を活用するようにしたのが、「説明に基づく学習 (Explanation-Based Learning, 以下 EBL と略記)」**である**。

類推を行う場合でも、やみくもに対象と類似例とを照合したのでは、無駄が多い。「説明」の導入は、関連する事柄としない事柄を区別して、この無駄を減らすのに有用であり、類推を問題解決に応用したり、類推の過程を効率化するために用いられている。たとえば、Winston の研究では因果関係が重要な役割を果たしており¹⁵⁾、論文中には明記されていないが、これは因果関係による「説明」を導入していることにはかならない¹⁶⁾。

説明に基づく学習の起源は問題解決にあるの

で、まず、問題解決と類推とのかかわりから出発し、類推における説明の役割について考察していく。

3.2 類推による問題解決

説明に基づく学習のルーツは STRIPS¹⁷⁾におけるマクロオペレータの獲得¹⁸⁾にある。STRIPS は問題解決システムの一種であり、部屋、ドア及び箱からなる世界で、ロボットの行動計画を作成する。たとえば、ロボットが図-3 の初期状態から目標状態 1 を達成するための計画を次のように立案する。

1. ドアの所に行く。
2. ドアを開ける。
3. ドアを通り抜ける。

学習機構付きの STRIPS¹⁸⁾では、過去に計画した問題解決手順を記憶しておき、その部分手順を組み合わせて、新しい計画を作る。この際、問題解決手順をただ記憶するのではなく、その手順が実際に目標を達成することを説明してから、その説明に基づいて一般化したマクロオペレータを記憶しているので、過去と異なった状況に対処する

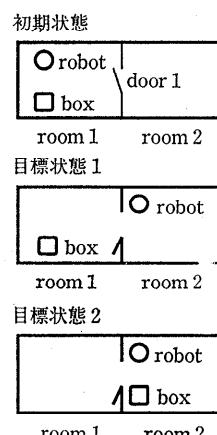


図-3 ロボットの行動計画

* ここでは演繹的な「説明」に話を限る。たとえばアブダクティブな説明については、文献 4) を参照。

** EBL については文献 14)などを参照されたい。

ことができる。

一方, Evans や Winston などの初期の類推研究では概念を取り扱っており, 問題解決への応用には触れていなかった¹⁹⁾. その後 Carbonell²⁰⁾ は問題解決にも類推機構を導入し、「類推による問題解決」を提案した¹⁵⁾. これが類推が問題解決にかかわるきっかけとなった.

その機構では, 類似した問題を見つけ出して, その解決手順を変形して新しい問題を解決する. すなわち, 上の例を解決した経験があった場合, 図-1 の初期状態から目標状態 2 を達成するためには, 上の計画を思いだしてその後半を変形し, 次の計画を得ることになる.

1. ドアの所に行く.
2. ドアを開ける.
3. 箱の所に行く.
4. 箱をドアまで押して行く.
5. 箱を押しながらドアを通り抜ける.

変形は「T(Transform) オペレータ」と呼ばれる次の各操作により, 順次行っていく.

一般的挿入, 一般的削除, 部分列埋め込み, 副目標保存置換, 最終段階連結, 初期段階連結, 連鎖融合, オペレータ再整序, パラメータ置換, 解連鎖除去, 連鎖反転

EBL のルーツである STRIPS の学習機構でも, 過去に計画した問題解決の手順を参照しているので, 単純な類推が行われている. Carbonell のシステムでは, 部分手順を組み合わせるだけでなく, 多様な変形を行っており, より複雑な類推にアプローチしている. ただし, 計算量がかなり大きくなることが予想されるが, その議論はなされていない.

STRIPS では, 過去の手順を参考する際に, オペレータ列 (=説明) に基づいて前提条件の後向き伝播を行い, マクロの適用条件を決定する. そのうえで手段-目的解析により, 目的の達成に関連したマクロのみを選んでいる. この手法は, T オペレータを使って手順を合成するよりも, はるかに効率がよい. 類推による問題解決に, STRIPS のような説明を参照する手法を取り入れ, 効率を改善したのが, 次に述べる「誘導類推」である.

3.3 誘導類推

類推による問題解決では, T オペレータにより, 過去の解そのものを変形していた. しかし

STRIPS の生成した操作列にむやみに挿入や削除を行っても希望する類推結果が得られることは少ない. 解の表現そのものより, 「箱を移動させるには, 箱を押していくかねばならず, まず箱の所に行く必要がある. さらに別の部屋に行くので, ドアをあらかじめ開けておく.」といった計画理由の説明に注目したほうがよい. Carbonell は, この観点から類推による問題解決法を改善し, 解を得る過程を変形して類推を行う「誘導類推」²¹⁾を提案した*. 小学生への訓示のようになってしまふが, 結果よりそれを得る過程のほうが大事なのである.

3.4 目的主導の類推

問題解決ではなく概念の類推のほうでは, 類似性の抽出に目的を導入することを, Kedar-Carbelli が提案し, 目的主導の類推と名付けた**. この方法は説明に基づく学習の一変形であり, ターゲットを説明してから類推を行う.

しかしながら, そもそも説明ができるならば, ベースからの類推などしなくとも, 結果が得られてしまい, 類推の意味がない. 同種のことは EBL でも問題になり, 「説明に基づくことによるパラドックス」と呼ばれた. 目的主導の類推が一見魅力的な提案であるにもかかわらず, 後に続く研究が少なかったのは, このパラドックスのためである.

確かに, 説明に基づく一般化(Explanation-Based Generalization)²²⁾や, 目的主導の類推で用いられた単純な機構および例では, 新しい知識が獲得されない. しかし, 人間の学習で考えてみると, たとえば, スキー理論を聞いたり, 数学の公式や代表的な問題の解法を暗記したりしただけでは駄目である. 実践的な訓練を通して, はじめて技能が獲得されるわけで, やはり体験からの学習や類推が必要である.

このパラドックスへの解答は次の二つを考慮することにより得られる.

● **推論効率**: 実際の推論は有限時間内に終えねばならない. 説明や理論を実行可能なレベルまで効率化しなければ, 結果を得ることができず, EBL や目的主導の類推はそれを行っている.

* Carbonell は STRIPS の例ではなく, 別の例を使って誘導類推の有用性を述べている. ただし展望だけを述べており, 細かな機構は報告されていない.

** 本特集の解説²³⁾ 3.2 参照.

●部分的な理論構築および洗練：人間の推論は柔軟で、説明を生成しながら部分的に理論を構築、修正することができる。この修正が学習や類推の重要なファクタになっている。

パラドックスが明らかになった後、EBL では上の二つに対応して研究が分化した。効率化に専念した研究としては、文献 23) がよく知られている。後者に対する研究としては、理論を構成する部品と目的とを入力することにより、説明を行なながら理論を構築し、類推を行う手法¹⁶⁾がある。さらに、EBL と協調して動作する帰納学習システムも提案されており²⁴⁾、「理論洗練システム」と呼ばれている。

3.5 類推における説明の役割——まとめ

本章では、問題解決における類推と概念の類推とを対象にして、類推における説明の役割を解説し、類推に説明を導入した場合に生じるパラドックスを解決する方法についても触れた。演繹と類推を完全に分離して考えるのは不可能であると言われており²⁵⁾、人間は演繹可能な部分を説明しておくことにより、アナロジーの対象を絞り込んでいると考えられる。したがって、類推における説明の役割を研究することにより、演繹と類推の両者がどのように融合されているかが解明できる。

4. 事例に基づくアプローチと類推

本章では、近年、新しい推論方式として注目を集めている事例に基づく推論 (Case-Based Reasoning, 以下 CBR と略記)、記憶に基づく推論 (Memory-Based Reasoning, 以下 MBR と略記) と、類推の関係について議論する。

4.1 事例に基づく推論 (CBR)

松原²⁶⁾によれば、CBR とは、基本的に以下のよ

うな推論方式である*。

1. 過去に経験した事例（問題・解答・解答を得る筋道）を事例ベースに蓄えておく。

2. 新たな問題の解答を得たいときは、まず、その問題に類似した既知の事例をベースから検索する。

3. こうして得られた既知の事例を利用することによって、解こうとしている問題の解答を得る。ここで、検索された既知の事例（問題）と、解こ

処 理

うとしている問題はまったく同じであるとは限らないので、検索された事例（解答・解答を得る筋道）を修正して適用することが必要になる。

4. こうして解かれた問題を、その解答や反省材料とともに事例ベースに収納する。

これより分かるように、CBR の一つのポイントは、類似した事例を利用して問題を解くという点にあり、これは、ある種の類推と考えることができよう。それでは、いったい、CBR と類推はどこが違うのであろうか。

それに対する答えは、それほど明確になっていないわけではないが、おそらく、以下のようなことになるのだと思われる。

• 研究の目的が違う。CBR 研究の目的は、もっぱら、実際に動くシステムを作ることにあるのに對し、類推研究の目的は、一般的な類推のメカニズムの解明にある。

つまり、CBR 研究は、対象領域に依存したメカニズムを採用して、現実の問題を解くことを目的とした応用指向の研究であるのに對し、類推研究は、対象領域から独立した類推のメカニズムを解明することを目的とした理論指向の研究であると言えよう。

4.2 記憶に基づく推論 (MBR)

MBR²⁷⁾とは、Connection Machine 上の超並列模倣推論方式であり、基本的には、以下のように推論を行う（図-4 参照）。

1. 実例をデータベースに登録する。MBR では、データベースはリレーションナルデータベースであり、実例は、その 1 レコードに相当する。1 レコードは複数の入力フィールドと出力フィールド

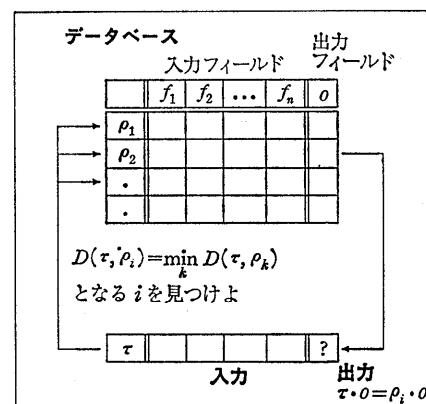


図-4 MBR の推論方法

* 人工知能学会誌 Vol. 7, No. 4 で、事例ベース推論が特集されている²⁸⁾。CBR の文献については、その特集を参照してほしい。

表-2 CBR, MBR vs. 類推

CBR	MBR	類推
実際に動くシステムを作る	実際に動くシステムを作る	類推のメカニズムを解明
応用指向	応用指向	理論指向
対象領域に依存	対象領域から独立	対象領域から独立
現実の問題	現実の問題	理想化された例題
比較的少数の事例	大量の事例	比較的少数の事例
複雑な事例（問題、解、解法）	単純な事例（入力、出力）	—
修正適用>類似検索	類似検索のみ	—
そこそこの計算資源	最高の計算資源	（計算オーダー）

からなり、実例では、そのすべてのフィールドの値が埋まっている。

2. 入力と実例の間に類似度（距離）を定義する。ここで、入力とは、入力フィールドだけが埋まっているレコードのことを指す。類似度は、それぞれの入力フィールドに対して、そこを埋めている二つの値の類似度に、その入力フィールドの重みを掛けたものを求め、その総和をとることによって計算する。

3. 入力と最もよく似た実例を模倣して、出力を得る。一般に似ている実例の上位 N 位までを考慮し、出力の値を決定する。

MBR で特徴的なことは、以下の 3 点である。

- 実例（データ）の数が非常に多い。数千から数万、あるいは、それ以上の実例を扱う。

- それゆえ、最も似ているものを見つけるための、類似度の定義が重要視される。実例集合の規則性を捕まえることができるような類似度を定義することが、MBR の中心的な課題となる。

- 類似度計算は、超並列処理を前提とする。

MBR も、CBR と同様に、類似した事例を利用して問題を解くという特徴をもっており、ある種の類推とみなすことができる。

類推研究という文脈においては、MBR は、類推の基底となる知識（ベース）の選択問題だけを扱っている。選択を可能とする類似性を、大量の実例（入出力ペア）だから決定する*. 御都合主義の『背景知識**』などを持ち込まない潔さと、計算資源をケチらない大盤振舞いに新しさがある。

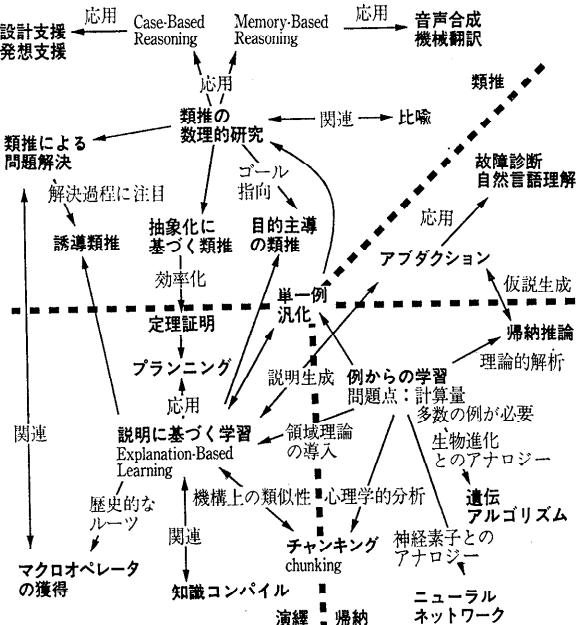


図-5 人工知能における類推研究の位置付け

4.3 類推, MBR, CBR の相互関係

以上、三者の関係を整理すると、以下のようなになるだろう（表-2 参照）。CBR も MBR も、応用指向という点で、類推研究と一線を画する。CBR の方向は、一つの事例に問題、解、解法など各種の情報をいろいろ書き込み、対象領域依存の類似性と対象領域依存の修正規則を使うことによって、力強く現実の問題を解こうという方向である。一方、MBR は、単純な事例を大量に用意し、超並列計算の力で現実の問題を解こうとするものである。

従来からの理論指向の類推研究と、新しい応用

* 正確には、類似度の定義に、ある種の知識が織り込まれている。

** 類推や学習研究では、類推や学習がうまくいくような背景（領域）知識を仮定することがよくある。理想化された例題ならば、そのような知識を準備することは可能だが、現実問題においては、事実上不可能である場合が多い。

指向の CBR, MBR 研究が、それぞれ相補的な役割を果たし、類推の理論から応用に至る広い範囲の、より一層の研究の発展を期待したい。

5. おわりに—人工知能における 類推研究マップ

人工知能における各種手法と「類推」の関係について述べてきた。最後に、人工知能における類推研究の位置付けをマップにまとめて図-5に示し、本稿のまとめとする。紙面の制約から舌足らずな解説となってしまったが、参考文献を参照くださることで補っていただければ幸いである。

参 考 文 献

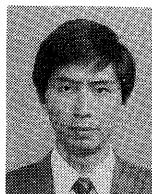
- 1) 有馬 淳：類推要素間の関連性に関する論理的分析、情報処理学会論文誌、Vol. 33, No. 7 (1992).
- 2) Arima, J.: Logical Structure of Analogy (Preliminary Report), in *Proc. of Int. Conf. on Fifth Generation Computer Systems (FGCS '92)*, ed. ICOT, pp. 505-513 (1992).
- 3) 有馬 淳、高橋真吾、原口 誠：アナロジーの数理的研究、情報処理、Vol. 34, No. 5, pp. 547-557 (1993).
- 4) 井上克巳：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).
- 5) Kling, R. E.: A Paradigm for Reasoning by Analogy, *Artifi. Intelli.* Vol. 2 (1971).
- 6) Laird, P. H.: 例からの学習、横森 貴訳、オーム社 (1992).
- 7) Mostow, J.: 1983 International Machine Learning Workshop: An Informal Report, *SIGART Newsletter 86*, ACM (1983).
- 8) Ohkawa, T., Mori, T., Babaguchi, N. and Tezuka, Y.: Analogical Generalization, in *Proc. of Int. Conf. on Fifth Generation Computer Systems (FGCS '92)*, ed. ICOT, pp. 497-504 (1992).
- 9) Peirce, C. S.: *Elements of Logic*, in: Hartshorne, C. and Weiss, P. (eds.), *Collected Papers of Charles Sanders Peirce*, Volume 2 (Harvard University Press, Cambridge, MA, 1932).
- 10) Plaisted, D. A.: Theorem Proving with Abstraction, *Artifi. Intelli.* Vol. 16 (1981).
- 11) Fujita, K. and Harao, M.: Proving Based on Similarity, in *Proc. of the 2nd workshop on Algorithmic Learning Theory (ALT '91)*, pp. 213-223 オーム社 (1991).
- 12) Tausent, B. and Bell, S.: Analogical Reasoning for Logic Programming, in Muggleton, S. (Ed.): *Inductive Logic Programming*, Academic Press, pp. 397-408 (1992).
- 13) DeJong, G. and Mooney, R.: Explanation-Based Learning: An Alternative View, *Machine Learning*, Vol. 1, No. 2, pp. 145-176 (1986).
- 14) 沼尾正行: 説明に基づく学習—領域固有の知識を用いたアプローチー、人工知能学会誌、Vol. 3, No. 6, pp. 704-711 (1988).
- 15) 半田、松原、石崎: 学習におけるアナロジー、人工知能学会誌、Vol. 2, No. 1, pp. 44-51 (1987).
- 16) 沼尾正行、志村正道: 説明構造の分解による類推、人工知能学会誌、Vol. 6, No. 5, pp. 716-724 (1991).
- 17) Fikes, R. E. and Nilsson, N. J.: STRIPS: A New Approach to the Application of Theorem Proving to Problem Solving, *Artifi. Intelli.* Vol. 2, pp. 189-208 (1971).
- 18) Fikes, R. E., Hart, P. E. and Nilsson, N. J.: Learning and Executing Generalized Robot Plans, *Artifi. Intelli.* Vol. 3, pp. 251-288 (1972).
- 19) 松原、折原、青木: アナロジー入門、情報処理、Vol. 34, No. 5, pp. 522-535 (1993).
- 20) Carbonell, J. G.: 類推学習: 過去の経験による計画の定式化と一般化、文献 26), 第 2 卷, 第 1 章, pp. 1-27 (1987).
- 21) Carbonell, J. G.: 誘導類推: 再生型問題解決と専門知識獲得に関する理論、文献 27), 第 7 卷, 第 2 章, pp. 25-51 (1988).
- 22) Mitchell, T.M., Keller, R.M. and Kedar-Cabelli, S.T.: Explanation-Based Generalization: A Unifying View, *Machine Learning*, Vol. 1, No. 1, pp. 47-80 (1986).
- 23) Minton, S.: *Learning Search Control Knowledge*, Kluwer Academic Publishers, Boston/Dordrecht/London (1988).
- 24) Tangkitvanich, S. and Shimura, M.: Refining A Relational Theory with Multiple Faults in the Concept and Subconcept, In *Machine Learning: Proc. 9th International Workshop (ML '92)*, pp. 436-444 (1992).
- 25) 原口 誠: 類推の機械化について、古川、溝口 (編), 知識の学習メカニズム、第 5 章, pp. 125-154, 共立出版 (1986).
- 26) Michalski, R.S., Carbonell, J.G. and Mitchell, T. M. editors: *Machine Learning: An Artificial Intelligence Approach*, Morgan Kaufmann, Los Altos, CA, 1983, 邦訳: 知識獲得と学習シリーズ第 1 ~ 3 卷, 共立出版 (1987).
- 27) Michalski, R.S., Carbonell, J.G. and Mitchell, T. M. editors: *Machine Learning: An Artificial Intelligence Approach (Vol. II)*, Morgan Kaufmann, Los Altos, CA, 1986. 邦訳: 知識獲得と学習シリーズ第 4 ~ 7 卷, 共立出版 (1987).
- 28) 松原 仁: 推論技術の観点から見た事例に基づく推論、人工知能学会誌、Vol. 7, No. 4, pp. 567-575 (1992).
- 29) 戸沢義夫編、特集: 「事例ベース推論」人工知能学会誌、Vol. 7, No. 4 (1992).
- 30) Stanfill, C. and Waltz, D.: Toward Memory-Based Reasoning, *Comm. ACM*, Vol. 29, No. 12, pp. 1213-1228 (1986).

(平成 5 年 1 月 13 日受付)



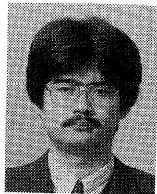
沼尾 正行（正会員）

1982 年東京工業大学工学部電気電子工学科卒業。1987 年同大学院情報工学専攻博士課程修了。工学博士。同年より東京工業大学工学部情報工学科勤務。現在、同学科助教授。1989-90 年スタンフォード大学 CSLI 客員研究員。人工知能、機械学習、関数型言語などの研究に従事。人工知能学会、日本認知科学会、日本ソフトウェア科学会、AAAI 各会員。



有馬 淳（正会員）

1984 年京都大学工学部情報工学科卒業。86 年同大学大学院修士課程修了。同年(株)富士通入社。同年(財)新世代コンピュータ技術開発機構へ出向。92 年 10 月より(株)富士通研究所(国際研)。人工知能全般に興味をもつが、現在は類推、帰納、説明などの論理的側面の研究に従事。91 年人工知能学会全国大会優秀論文賞、92 年同学会研究奨励賞受賞。人工知能学会、ソフトウェア科学会各会員。



佐藤 理史（正会員）

1983 年京都大学工学部電気工学第二学科卒業。1988 年同大学院工学研究科博士課程研究指導認定退学。同年より京都大学工学部電気工学第二教室助手。1992 年より北陸先端科学技術大学院大学情報科学研究科助教授。工学博士。人工知能、特に、機械学習、自然言語処理に興味をもつ。人工知能学会、認知科学会、ソフトウェア科学会各会員。

