

並列推論ネットワーク：スキーマの表現と並列探索†

生 天 目 章^{††} 大 澤 洋 一^{††}

ニューラルネットワーク情報処理による高次認知処理問題を実現するためのアプローチとして、コネクショニスト記号処理モデルが注目されている。本モデルはニューラルネットワーク情報処理の原理を自然言語処理や意志決定支援問題といった高次認知処理問題に適用するために、ネットワークの知識表現能力を向上させる方法論の確立を主な目的としている。本研究は、複雑な階層構造を持つ対象領域に関する概念や状況をネットワークの学習メカニズムにより表現する方法として並列推論ネットワークを提案する。1つの概念や状況は複数の知識の構成単位の組合せにより表現され、知識の基本単位は複数の上位レベルの概念や状況の構成要素になる。また、概念や状況間には階層構造が存在し、下位概念は上位概念の構成要素になる。このような複雑な階層構造を表現するために、記号処理モデルの知識表現法ではポインタが用いられる。並列推論ネットワークによる知識表現とは、知識間の相互関係をポインタのような固定された一本のリンクではなく、重み付けされた複数のリンクにより対応付け、表現する方法である。そのような知識間の複数のリンクの結合係数は知識間の包含関係を学習例として、学習アルゴリズムにより獲得する。本アプローチをスキーマの表現と並列探索問題に適用し、並列推論ネットワークの知識表現能力について検証する。また、ネットワークの新しい学習アルゴリズムとして瞬時学習法を提案し、学習例を一度提示するだけでリンクの結合係数が求められることを示す。

1. はじめに

人間のもつ高次認知情報処理機能をコンピュータシステム上で実現するためには、知識表現、推論および知識獲得が重要なテーマである。記号処理モデルによる知識表現の形式として、プロダクションルール、フレーム、意味ネットワークなどの様々な手法が提案されている。それらの表現形式は、高次認知情報処理を実現する上で不可欠な複雑な構造を持つ知識の表現や推論を容易にする。記号処理モデルの推論は、基本的には記号に付加されるアドレスまたはポインタの追跡および記号間のパターンマッチングによって実現される。推論戦略の選択およびその実行は、推論制御の問題として捉えられている。逐次型のコンピュータで並列的推論を実現するためのソフト面、ハード面での様々な研究が行われている^{19), 22)}。さらに、記号処理モデルにおける知識獲得の研究で、問題領域における表層的な知識だけでなく背景となる深い知識(メタ知識)を獲得するための研究が盛んに行われている。

記号処理モデルの利点は、複雑な構造をもつ知識集合に対して強力な表現能力を有している点である。また知識を記号によって明示的に表現することによりシステム設計者およびユーザが知識の内容を理解することが容易になりシステムのタスク実行過程を明示的に

説明することが可能になる点にある。しかしながら、知識表現が記号主体であるため、その情報処理は記号のマッチングに基づくため、推論プロセスに柔軟性がなく、また推論プロセスが逐次的な情報処理に基づいている。さらに、知識集合に明示的に表現されていない未知情報に対して推論プロセスを適用することが難しく汎化能力が欠如する。そして、有効な知識獲得能力が明らかにされていないといった問題点が指摘されている。

コネクショニストモデルは、人間の神経細胞の振舞いに似た情報処理要素(以下ユニットという)により構成されるネットワーク情報処理モデル^{7), 15)}である。ネットワークアーキテクチャには、相互結合型、多層型などが提案されているが¹¹⁾、それらの共通的特徴として、学習に基づく自己組織化および超並列情報処理機能がある。近年の研究において、画像処理、音声認識および制御の分野におけるパターン識別的な問題(低次認知情報処理)に数多く適用されている²¹⁾。そのような発展に呼応し、コネクショニストモデルを低次認知情報処理問題から高次認知情報処理問題(自然言語理解、画像理解、意志決定問題など)への問題領域を広げようとする研究(以下、コネクショニスト記号処理モデルという)が注目されてきている^{1), 9)}。

現在のコネクショニストモデルのフレームワークを知識処理や推論の問題に適用していく上で次のような問題がある^{5), 8)}。第1に複雑な構造をもつ知識を表現し、利用できない、第2に、表現する知識が暗示的であるという点である。それは、ネットワークに多くの

† Parallel Inference Networks: Schema Representation & Parallel Search by AKIRA NAMATAME and YOICHI OHSAWA (Department of Computer Science, National Defense Academy).

†† 防衛大学校情報工学科

隠れ層が設けられることにより、ネットワークの内部表現の明示化が難しくなることに起因する。

本研究では、構造化知識に基づく並列推論をコネクショニストモデルにより実現する方法として並列推論ネットワークを提案し、知識の学習と推論を1つの統合されたネットワーク上で実行するための方法を示す。並列推論ネットワークとは、ネットワークの多層構造化により、構造化知識に基づく多段階推論メカニズムを表現するものである。並列推論ネットワークの学習アルゴリズムとして瞬時学習法を提案する。誤差逆伝播法といった従来の学習アルゴリズムは学習例の提示を数多く必要とするのに対し、瞬時学習法は1回の学習例の提示で結合係数を獲得することができる。さらに、ネットワークの未知パターンに対する汎化能力も顕著に改善できることを示す。スキーマは、人間の知識の内部表現モデルに関する研究の中心的な概念であるばかりでなく、工学的な知識システムを実現する上でも重要な概念である。スキーマの上位概念および下位概念としてさらにスキーマを持つような複合的なスキーマを並列ネットワークにより表現する方法と、現在の状況に最も適したスキーマを並列的に推論する問題についてシミュレーションを行い、並列推論ネットワークの有効性について検証する。

2. コネクショニストモデルの知識表現と問題点

コネクショニストモデルの知識表現は、ユニット間の結合関係および結合係数の形式で行われる。結合係数は、表現対象の知識集合に応じて構成される学習例集合に基づき、ネットワーク学習を行うことにより獲得される。したがって、コネクショニストモデルの知識表現と学習は表裏一体の問題である。コネクショニストモデルによる推論は、入力ベクトルによる入力層の活性パターンが隠れ層を経由して出力層に伝播し、それに基づいた出力層の活性パターンに基づき行われる。ネットワークの学習により、学習例集合にない未知の学習例に対しても正しく推論できる特徴がある。これはネットワークの汎化能力として捉えられ、先述したとおり記号処理モデルにはない。

コネクショニストモデルにおける知識表現の研究においては、ユニット構成および結合係数の獲得に関して2つの考え

方がある。1つは局所的表現法⁹⁾であり、もう1つは分散的表現法^{10),11)}である。同一問題を両者の表現法により表現することにより、その利/不利を明らかにする。問題は {A, B, C, D} の4つの文字で表現される論理式をアトムとして持つ、次の4つの概念を表現することである。

$$\begin{aligned}
 C_1: & ((AB)(CD)) \\
 C_2: & ((CD)(AB)) \\
 C_3: & ((BA)(DC)) \\
 C_4: & ((DC)(BA))
 \end{aligned}
 \tag{2.1}$$

すなわち、(2.1)のそれぞれの概念は、それぞれ2つのアトムから構成される2つのリストを持つリスト構造として表現される。(2.1)の構造を持つ知識を局所的方法により表現するためのネットワークアーキテクチャは、次のように構成される。図1に示すように、ネットワークの構成は、論理式 $((X_1, X_2)(X_3, X_4))$ のそれぞれの位置 X_i に対応させたユニットを入力層に配置し、中間層には入力層のユニットの組合せにより表現されるリスト (AB), (BA), ..., (DC) に対応するユニットを配置し、出力層には表現対象であるそれぞれの概念 C_j に対応させたユニットを配置することで行う。ユニット間の結合係数は各層のユニット間の関係により決定されるが、図1の例ではそれぞれのリンクは +1 の固定された重みを持つ。局所的表現法は、問題領域における知識の表現形式および構造が明確に規定されているときに、その表現能力は強力である。それに加え、各ユニットの持つ役割や意味が明示化できる利点がある。記号処理モデルの代表的な知識表現法である意味ネットワークやフレームは、局所的表現法の一つと見ることができる。ネットワークの汎化能力とは、一部の論理式が不明であるような入力パターンに対し最も類似した概念を導出するためにも必




図1 局所的表現法による知識表現
Fig. 1 Local representation.

要な能力である。局所的表現法では結合係数が一定の重みとなり、未知の概念に対してネットワークは汎化能力を有していない。図1の例では、入力パターン(((AB)(--))や((A-)(C-))(-は不明を表す))に対して、ネットワークは最も類似した概念(C₁:((AB)(CD)))を想起することはできない。さらに図1の例でも明らかのように、それぞれの論理式のアトムが重複して含まれる場合、同じユニットを何度も配置することになりネットワークが大規模になるといった問題がある。一方、分散的表現法は、入力層に論理式 X_i の位置に対応した4つのユニットを配置し、出力層に概念を表すユニット C_j およびいくつかの中間ユニットを配置することでネットワークを構成する。しかしながら、このような方法では、(2.1)のような構造化知識を表現することはできない。

そこで、図1の局所的表現法のアーキテクチャにおいて中間層を持たない2層ネットワークを利用して表1の学習例集合を学習させる。ユニット間の結合係数は学習アルゴリズムに基づくネットワーク学習により獲得される。これにより、概念は入力ユニットの活性パターンによって表現される。獲得された結合係数は学習によるものであるため、未学習のパターンに対しても学習したパターンからそれと類似した概念を導出できる。例えば、例として上記に示した未知パターン(((AB)(--))や((A-)(C-))に対して、概念 C₁ を推論することができる。したがって、汎化能力は先の局所的表現法より優れている。またユニット数も制約でき、ネットワークの規模の問題も解決するという利点がある。知識の構成要素であるアトム(論理式)の關係に意味があるとするように、対象とする概念の内部表現を適切に表現するためには、知識の構成要素に対応したユニットの構成だけでなく、それらの關係構造を表現することが必要で、それらは学習例集合の構成法に依存している。

表1 分散的表現法のための学習例集合
Table 1 Training set for the distributed representation.

入 力																出 力			
X ₁				X ₂				X ₃				X ₄				C ₁ , C ₂ , C ₃ , C ₄			
A	B	C	D	A	B	C	D	A	B	C	D	A	B	C	D	C ₁	C ₂	C ₃	C ₄
1	0	0	0	0	1	0	0	0	0	1	0	0	0	0	1	1	0	0	0
0	0	1	0	0	0	0	1	1	0	0	0	0	1	0	0	0	1	0	0
0	1	0	0	1	0	0	0	0	0	0	1	0	0	1	0	0	0	1	0
0	0	0	1	0	0	1	0	0	1	0	0	1	0	0	0	0	0	0	1

3. 並列推論ネットワークの知識表現と推論

構造化知識は、問題領域の対象(オブジェクト)を特徴付ける属性(内包的知識)と対象間の關係(外延的知識)に分類される。内包的知識は、対象-属性-属性値の3つ組のベクトルを用いて表現し、外延的知識は対象-關係-対象の3つ組のベクトルで表現する。3つ組のベクトルで表現される内包的知識または外延的知識を知識アトムと定義する。また知識アトムを構成する対象、属性、属性値または關係を知識アトムの構成要素(primitive)と呼ぶ¹⁶⁾。知識アトムをネットワーク表現するために、まずユニット構成を以下のとおり行う。知識アトムの構成要素に対応した特徴ユニットを入力層に配置し、知識アトムユニットを出力層に配置する。知識アトムユニットは、構成要素のベクトルにより表現される知識アトムを表す。知識アトムがより複雑な構造を持つ上位概念を表現するために利用される場合は、知識アトム層の上に知識アトムのベクトルにより表現される概念に対応したユニットを配置し、表現の対象となる上位概念に対応するユニットを出力層に配置したネットワークによって表現する。その場合の上位概念を表すユニットは知識アトムを入力層とするベクトルにより表現される知識と考えることができる。並列推論ネットワークとは、このようにそれぞれが知識の持つ構造レベルに対応した意味のある2層ネットワークを多層に重ねた構造化多層ネットワークである。概念や状況は、知識の基本単位の包含關係により特徴付けられる。すなわち、1つの概念や状況は複数の知識の基本単位の組合せにより特徴付けられ、また1つの知識の基本単位は複数の概念や状況の構成要素になる。また、概念や状況間には階層構造が存在し、下位概念は上位概念の構成要素になる。このような複雑な階層構造を表現するために、記号処理モデルに基づく知識表現法ではポインタが用い

られる。並列推論ネットワークによる知識表現とは、知識間の相互關係をポインタのように固定された一本のリンクではなく、重み付けされた複数のリンクにより対応付け、表現する方法である。そのような知識間の複数のリンクの結合係数は知識間の包含關係を学習例としてネットワークの学習アルゴリズムにより獲得する。

分散的表現法で表現された構造化知識に基づく推論においては、制御機構を別に付加する（外部制御機構の付加またはネットワークの内部表現に記号処理モデルのポインタ機能を付加するなど）必要がある^{10), 18)}。しかしながら、制御機構の付加によりモデルの並列的な情報処理が逐次的なアーキテクチャの制約を受ける。並列推論ネットワークは、分散的表現および局所的表現の中間的なアプローチとして、強力な知識表現と推論能力を持つ。そして、表現される知識構造が並列推論ネットワーク内のモジュール構造に転化されているため、推論においては、単にユニットの活性化パターンをモジュール間で伝播することによってその推論結果を得ることが可能になる。並列推論ネットワークとは、複雑な階層構造を持つ対象領域に関する概念や状況をネットワークの学習メカニズムにより表現する方法である。並列推論ネットワークの推論メカニズムは、ネットワークの学習プロセスによりネットワーク構造として獲得される。

4. 瞬時学習法

パセプトロンや誤差逆伝播法などのような誤差訂正型学習アルゴリズムは、入力層と出力層との間で適切な結合係数を獲得するために適用することができる。しかしながら、それらのアルゴリズムは様々な欠点を抱えている。誤差訂正における学習戦略は、信号誤差に比例するようなある一定の量によってすべての結合係数を調整しようとする。例えば、誤差逆伝播法は入力ベクトルを対応する望ましい出力ベクトルへ変換するために、そのあいだの2乗誤差を最小化する方向へと漸次降下するような学習を行うが、その収束は必ずしも最小点に到達するとは限らず、またその収束の過程において学習例を繰り返し提示しなければならない。したがって、こうした強化学習は入力特徴や学習例が数多い場合には特に非効率的な学習戦略になる。またこれらのアルゴリズムは汎化を促進するのに必要な入力特徴の重要または重要でない側面の識別を助長するかどうか不明確である。

本研究で提案する瞬時学習法は先述した強化学習戦略の欠点を克服するために以下の特性を有する。第1に、1回の学習例の提示により結合係数を獲得できる⁴⁾。第2に、各ユニットが学習例に対して構成するベクトルの内積に着目することによって入力特徴にみられる類似性を明示化し、ネットワークの汎化能力を促進することができる^{3), 20)}。以下そのアルゴリズムに

ついて紹介する。

4.1 学習アルゴリズム

入力ベクトル X の要素 $x_i, i=1, 2, \dots, n$, で i 番目の入力ユニットの値を表し、出力ベクトルの要素 $o_j, j=1, 2, \dots, k$, で j 番目の出力ユニットの値を表す。 x_i および o_j のとる値は2値とする ($x_i, o_j \in \{0, 1\}$)。また、 x_i および o_j との間の結合係数を w_{ij} で表す。

<学習ルール>

- (a) $\Delta w_{ij} = \alpha_j$ if $x_i = 1$ and $o_j = 1$
- (b) $\Delta w_{ij} = -\beta_j$ if $x_i = 1$ and $o_j = 0$
- (c) $\Delta w_{ij} = 0$ if $x_i = 0$ (4.1)

(4.1)のルールに基づき、学習例集合のすべての学習例を提示することにより決定される最終的な結合係数 w_{ij} は(4.2)式で与えられる。なお、学習例の集合 T の部分集合で、出力要素 o_{jt} が1の学習例の集合を $T_j = \{t | o_{jt} = 1\}$ で表し、 o_{jt} が0の学習例の集合を $T \setminus T_j = \{t | o_{jt} = 0\}$ で表す。

$$\begin{aligned} w_{ij} &= \alpha_j \sum_{t \in T_j} x_{it} o_{jt} - \beta_j \sum_{t \in T \setminus T_j} x_{it} (1 - o_{jt}) \\ &= \alpha_j \sum_{t \in T_j} x_{it} - \beta_j \sum_{t \in T \setminus T_j} x_{it} \end{aligned} \quad (4.2)$$

(4.1)の学習ルールについて以下のような定理が知られている¹³⁾。なお、 $(x_t, x_{t'})$ は t および s 番目の学習例の内積、 w_{ij} は(4.2)式で定義される結合係数、 θ_j は(4.3)式で定義されるしきい値とする。

$$\begin{aligned} \theta_j &= -1/2 [\text{Min}_{s \in T_j} \{ \alpha_j \sum_{t \in T_j} (x_t, x_s) \\ &\quad - \beta_j \sum_{t' \in T \setminus T_j} (x_{t'}, x_s) \} \\ &\quad + \text{Max}_{s' \in T \setminus T_j} \{ \alpha_j \sum_{t \in T_j} (x_t, x_{s'}) \\ &\quad - \beta_j \sum_{t' \in T \setminus T_j} (x_{t'}, x_{s'}) \}] \end{aligned} \quad (4.3)$$

[定理 4.1]: 各々の出力ユニットに対応してある係数 $\alpha_i, \beta_j > 0, j=1, 2, \dots, k$, が存在し、すべての $t \in T_j$ および $t' \in T \setminus T_j$ に対して

$$\begin{aligned} \alpha_j \sum_{s \in T_j} (x_t, x_s) - \beta_j \sum_{s' \in T \setminus T_j} (x_t, x_{s'}) &> 0 \\ \alpha_i \sum_{s \in T_j} (x_{t'}, x_s) - \beta_j \sum_{s' \in T \setminus T_j} (x_{t'}, x_{s'}) &< 0 \end{aligned} \quad (4.4)$$

が成立するならば、次式で定義される関数は各出力ユニットの線形識別関数になる。

$$f_j(w_j, x) = \sum_{i=1}^n w_{ij} x_i + \theta_j \quad (4.5)$$

ここで、 $w_j = (w_{1j}, w_{2j}, \dots, w_{nj})$ 。

また(4.2)式で定義される結合係数は以下の手順によ

り求められる。

[結合係数の決定手順]

ステップ1: 相関行列の計算

各入力ベクトル間の内積を表す相関行列 $Y = \{y_{ij}; i, j=1, 2, \dots, T\}$ を求める。ここで、 Y は

$$Y = X * X^T \quad (4.6)$$

で与えられる (X^T は学習例集合 X の転置行列)。

ステップ2: 学習修正パラメータ (α_j, β_j) およびしきい値 (θ_j) の決定

相関行列の各列ベクトル $y_j = (y_{1j}, y_{2j}, \dots, y_{Tj})$ において ($j \neq i$),

$$\alpha_j y_{ij} - \beta_j \sum_{k \neq j} y_{ki} + \theta_j > 0 \quad (4.7)$$

$$\alpha_j y_{ij} - \beta_j \sum_{k \neq i} y_{kj} + \theta_j < 0$$

がすべての列ベクトルに対して、成立する $\alpha_j, \beta_j, \theta_j$ を求める。

ステップ3: 結合係数 w_{ij} の決定

ステップ2で求めた α_j, β_j に対して

$$w_{ij} = \alpha_j \sum_{t=1}^T x_{it} o_{jt} - \beta_j \sum_{t=1}^T x_{it} (1 - o_{jt}) \quad (4.8)$$

を求めることにより結合係数 w_{ij} が求められる。

4.2 誤差逆伝播法との比較

入力ユニットの数を n 個, 出力ユニットの数を k 個とすると, (4.6), (4.7) および (4.8) の手順によって結合係数およびしきい値を求めるために必要な計算量は $O(nk^2)$ である。一方, 誤差逆伝播法による場合の必要な計算量は $O(nk^2L)$ である。ここで L は, 誤差逆伝播法の学習回数とする。したがって, 瞬時学習法の計算量は誤差逆伝播法の1回の学習回数に必要な量と同程度である。

(4.1)の学習ルールは, 相関学習¹¹⁾や学習行列アルゴリズム¹²⁾と類似しているが, いずれの方法も結合係数が負の値にならないよう(4.1)の(b)に基づく修正パラメータは小さく抑えられている。瞬時学習法は負のパラメータに対する修正は正のレベルと同じように大きなものとし, 抑制型の結合係数の獲得を学習において重視している点に特徴がある。

ここでは, 図2に示す隣接行列形式の領域知識を表現する問題を考える。領域知識は状況 S_j ($j=1, 2, \dots, 20$) が構成要素 e_i ($i=1, 2, \dots, 29$) によって表現され

$e_i \setminus S_j$	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
1	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●
2	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●
3	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●
4	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●
5	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●
6	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●
7	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●
8	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●
9	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●
10	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●
11	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●
12	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●
13	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●
14	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●
15	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●
16	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●
17	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●
18	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●
19	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●
20	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●
21	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●
22	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●
23	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●
24	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●
25	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●
26	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●
27	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●
28	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●
29	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●

図2 学習アルゴリズム比較のための知識

Fig. 2 Knowledge representation in a matrix form used for comparing learning algorithms.

ていることを示している。誤差逆伝播法による学習とは, 入力ベクトルにより活性化される出力ベクトルと学習例における出力ベクトルとの間の誤差を各種降下法によって最小値に収束する手続きで実行される。学習例に対する調整は, 入力ベクトルと出力ベクトルが構成する行列の行ベクトル単位に行う。したがって, 獲得された結合係数は学習例集合に対して大域的制約関数の収束の結果からもたらされるものであり, 必ずしも知識全体の構造を反映したものにはならない。表2(b)に誤差逆伝播法により獲得された結合係数の一部を示すが, $e_i=1, S_j=1$ となっている対応関係を表す結合係数 w_{ij} が必ずしも正値をとらないことから理解できる(網掛け文字の部分)。

瞬時学習法による結合係数の獲得は, 4.1節の学習アルゴリズムにより行われる。表2(a)に獲得した一部の結合係数を示すが, (4.1)のルールの特性から $e_i=1, S_j=1$ となる対応関係に対して, 正値の結合係数が獲得されている(網掛け文字の部分)。またその大きさは(4.2)式により決定されるが, ある構成要素 e_i が複数の S_j に対して1の値をとる場合が多ければ多

表 2(a) 瞬時学習法による結合係数
Table 2(a) Weight acquired by flash learning.

	S1	S2	S3	S4	S5
θ_j	-3.00	-3.00	-3.00	-3.00	-3.00
e1	1.70	1.70	-1.00	-1.00	1.70
e2	2.00	-1.00	-1.00	-1.00	2.00
e3	2.00	-1.00	2.00	2.00	2.00
e4	-1.00	-1.00	-1.00	-1.00	-1.00
e5	1.70	-1.00	1.70	1.70	1.70
e6	4.00	-1.00	-1.00	-1.00	4.00
e7	4.00	-1.00	4.00	4.00	4.00
e8	-1.00	-1.00	-1.00	-1.00	-1.00
e9	-1.00	-1.00	-1.00	-1.00	-1.00
e10	-1.00	-1.00	5.00	5.00	-1.00
e11	-1.00	7.00	-1.00	-1.00	7.00
e12	-1.00	-1.00	-1.00	-1.00	-1.00
e13	-1.00	-1.00	-1.00	-1.00	-1.00
e14	7.00	7.00	-1.00	-1.00	-1.00
e15	-1.00	-1.00	-1.00	-1.00	4.00

表 2(b) 誤差逆伝播法により獲得された結合係数
Table 2(b) Weight acquired by back-propagation.

	S1	S2	S3	S4	S5
θ_j	-3.31	-3.18	-1.35	-2.11	-2.07
e1	-0.97	-1.53	-2.67	-1.57	-1.97
e2	-0.61	-0.69	-1.36	-1.11	-1.66
e3	-0.85	-2.78	0.15	0.11	1.41
e4	0.30	-0.84	0.59	-0.82	-0.92
e5	-1.35	-2.33	0.67	0.61	-1.23
e6	-1.33	-0.29	-0.87	-0.92	-0.38
e7	0.15	0.65	0.71	0.24	0.08
e8	-1.91	-0.52	0.70	1.64	-0.91
e9	-1.02	-1.99	0.95	0.71	-0.33
e10	-1.47	-0.98	1.08	1.78	-0.13
e11	-0.35	0.38	-1.19	-0.92	0.49
e12	0.75	-0.93	0.53	0.11	0.85
e13	-0.42	-2.05	-0.85	-0.51	-1.64
e14	-1.33	2.07	-0.39	-0.11	-0.27
e15	0.15	-1.35	-0.19	-0.49	-0.29

いほど、 w_{ij} のとる値が相対的に小さくなるのが理解できる。それは(4.1)式の性質から明らかであるが、表 2(b)に示された結合係数においても明確に現れている。換言すれば、結合係数の大小は構成要素の状況の識別における貢献度によって決められるということである。また、誤差逆伝播法では、学習例に対する結合係数の調整を繰り返し小さな値で行う必要がある(本事例における学習回数は 500 回であった)のに対し、瞬時学習法においては学習例の提示は α_j , β_j を決定するときに 1 回提示するだけで済む。誤差逆伝播法により獲得された結合係数に基づく推論は、入力情報に対して学習例集合内のパターンとのマッチングを行い、それに特化した推論結果を導出する。それに対し、瞬時学習法により獲得された結合係数に基づく推論は、入力情報を全体の知識集合内のパターンとして捉え、集合の構造に基づいた推論結果を導出する。

5. スキーマの表現と並列探索

5.1 スキーマの表現法

人間は個人的な経験を通じ広範囲に渡って汎化・抽象化された知識を多数蓄積していくが、それらは互いに高度に構造化され、組織化される必要がある。心理学で導入された概念にスキーマ (schema) がある^{2),14)} が、それは未定義の概念ながら、汎化・抽象化され、さらに構造化・組織化された知識の単位を示していると考えられている。スキーマの記号処理モデルによる実装は様々な研究が行われているが、代表的なものはフレームシステムである。フレームシステムでは、スキーマはフレームと呼ばれるデータ構造により表現される。フレームはそのモデルの特性からスキーマを容易に表現することができる。しかしながら、フレームに基づく推論を実行するためのフレーム探索用の制御メカニズムの実装が困難な課題である。特に、状況に応じたフレームの想起またはそのスロットの充足は、逐次的処理では時間のかかるタスクとなっている。本節では複数のスキーマ群を並列推論ネットワークにより表現し、探索する方法について考察する。並列推論ネットワークの構造的な知識表現により、複雑な構造を有するスキーマを適切に表現することができることを示す。

対象とするスキーマの構造は以下のとおりである。最上位にある上位スキーマは、3種類の建築物に関するスキーマである。図 3 に示す 3 種類の上位スキーマは、8種類の部屋に関するスキーマから構成される。スキーマの認識および想起はそれぞれの構成要素を並列的に導出し、その結果に基づいて行う。上位スキーマとなる建築物は、例えば、アパートであればそれを構成するスキーマは、居間、台所、浴室、トイレ、寝室の 5 種類である。スキーマ群は上位スキーマ間で共通なもの(例;トイレ)と、個別的なもの(例;事務所のコンピュータールームや研究室、など)がある。部屋のスキーマは 8 種類あり、その各々は多種類の対象および対象間の関係に関する 2 種類の知識アトムから構成される。例えば、研究室は天井、壁(左右)、床、窓、ドア、本棚、机の 8 種類の対象群と「窓は机の上」、「本棚は机の左」などといった対象間の相互関係から構成される。各スキーマを構成する対象群は、各対象を特徴付ける属性-属性値の組 (A-V 表現) により表現され、また対象間の関係に関する知識は対象-関係-対象の組 (O-R-O 表現) により表現される。

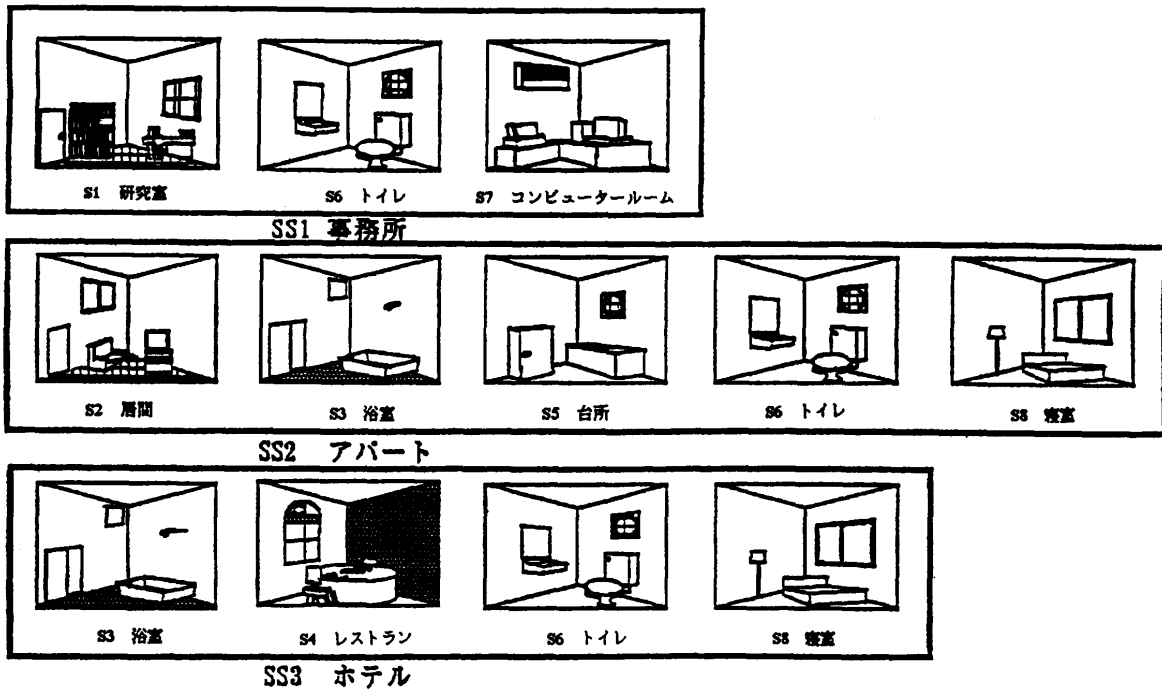


図 3 部屋および建築物に関するスキーマ表現
 Fig. 3 Schema representation on various rooms and buildings.

それらの2種類の知識を知識アトムと定義する。知識アトムは、いくつかのスキーマ群に共通して存在するもの(天井、壁(左右)、床はすべてに共通)もあり、各スキーマで個別的に存在するもの(例; 研究室の本棚、居間のソファ・テレビ、など)もある。

人間がこれらのスキーマを認識する過程においては、まず部屋に関するスキーマであることを認識するために、一般的な部屋のスキーマの要素となる対象を個別的に認識した上で、その相互関係に基づいて全体の情景を部屋と認識する。次に、両者間の差別化の要因となる対象を個別的に認識し、それと共通対象との相互関係により各スキーマを認識していくものと考えられる。他方、人間が部屋に関するスキーマを認識した上で、改めて部屋の情景を想起する過程においては、スキーマを構成する対象に着目し、それが何を示し、他者といかなる関係を持っているかを判断した上で情景を再構築して結論を導出するものと考えられる。上述した認識および想起の

過程は、両者とも人間の頭脳の中では並列的な情報処理により極めて短時間に行われているものと考えられる。

図4は、部屋のスキーマを記号処理モデルにより表現した例を示している。この例では部屋を構成する対象またはそれを特徴付ける概念をノードにし、その間の関係をリンクで示している。リンクには、その関係

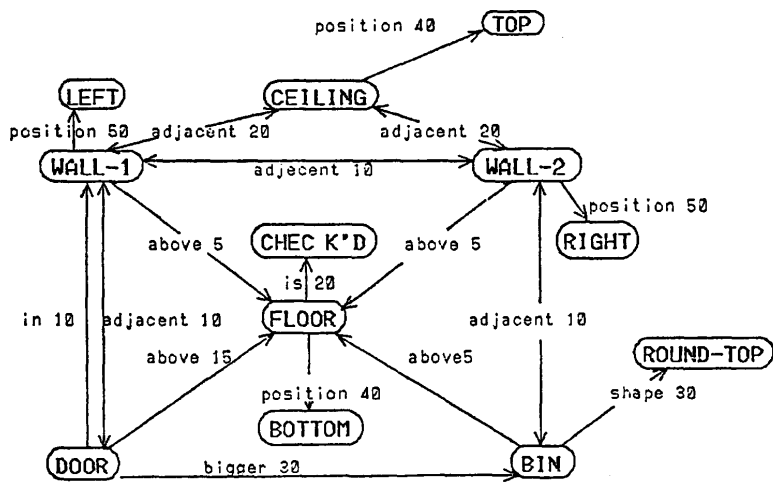


図 4 記号処理モデルによる表現
 Fig. 4 Semantic representation for a room. The number adjacent to the link is used for searching an object.

を表すラベルと共に重みをかけられている。その重みは対象を認識する上での確信度とモデルに基づく推論を行う上での確信度となるが、それはモデルの全体構造に対して固定的に獲得される。こうした表現はスキーマを構造的に表現するために有効である一方で、ノードを特定化するための推論はノードおよびリンクのラベルとの記号的マッチングと確信度の計算によって行われるため、記号処理モデル固有の問題をそのまま引き継ぐ。特に、状況に応じたスキーマを想起する場合に処理のための時間が必要となる。

スキーマを並列推論ネットワークにより表現し、それに基づいた超並列的な推論を可能にするため、以下のネットワークアーキテクチャを構成する。部屋の情景に関するスキーマを構成する特徴ユニット、対象ユニット、知識アトムユニットおよび概念ユニットの一覧表を表3に、またそれらの相互依存関係表を表4に示す。

5.2 ネットワークアーキテクチャの構成

スキーマの認識および想起を実装するための並列推論ネットワークは2層ネットワークで構成される4つのネットワークモジュールを必要とする。第1モジュールは対象を表現する知識アトムをA-V表現により表現し、第2モジュールは対象間の関係を表現する知識アトムをO-R-O表現により表現し、第3モジュールは対象の連言および対象間の関係により各スキーマを表現し、そして第4モジュールはスキーマの連言により各上位スキーマを表現する。これら4つのネットワークモジュールを階層的に結合することによって図5に示す並列推論ネットワークを構築する。各ネットワークモジュールの構成は次のとおりである。第1モジュールは部屋の構成物である対象を表現するための2層ネットワークモジュールである。ユニット構成は、入力層に属性および属性値に対応するユニットを、出力層に対象を表す内包的知識アトムユニットを配置する。本事例では、属性を位置、形状および表面の模様限定した。色、構成物質などのような必要に応じた属性の拡張は、属性および対応する属性値に応じたユニットを配置することで可能になる。例え

表 3(a) ユニット一覧表 (その1)
特徴ユニットおよび内包的知識アトムユニット
Table 3(a) The table of unit types.
(Feature units and inclusive knowledge atom units.)

属性ユニット		属性値ユニット		特徴ユニット
記号	意味	記号	意味	
A 1	位置	V 1	右	c 1 (A 1 V 1)
A 2	形状	V 2	左	c 2 (A 1 V 2)
A 3	表面	V 3	中央	c 3 (A 1 V 3)
		V 4	下	c 4 (A 1 V 4)
		V 5	上	c 5 (A 1 V 5)
		V 6	方形	c 6 (A 2 V 6)
		V 7	楕円	c 7 (A 2 V 7)
		V 8	円頭	c 8 (A 2 V 8)
		V 9	その他	c 9 (A 2 V 9)
		V 10	チェック	c 10 (A 3 V 10)
		V 11	タイル	c 11 (A 3 V 11)
		V 12	平滑	c 12 (A 3 V 12)
		V 13	その他	c 13 (A 3 V 13)

内包的知識アトムユニット			
記号	意味	記号	意味
o 1	壁-1	o 16	テーブル
o 2	壁-2	o 17	腰掛け-1
o 3	床	o 18	腰掛け-2
o 4	天井	o 19	窓-3
o 5	窓-1	o 20	流し台
o 6	机-1	o 21	冷蔵庫
o 7	椅子	o 22	換気扇-2
o 8	本棚	o 23	便器
o 9	ドア	o 24	洗面台
o 10	テレビ	o 25	コンピュータ
o 11	ソファ	o 26	プリンタ
o 12	窓-2	o 27	机-2
o 13	浴槽	o 28	エアコン
o 14	シャワ	o 29	ベッド
o 15	換気扇-1	o 30	スタンド

表 3(b) ユニット一覧表 (その2)
 関係ユニットおよび外延的知識アトムユニット
 Table 3(b) The table of unit types.
 (Relation units and extensive knowledge atom units.)

関係ユニット	外延的知識アトムユニット			
	記号	意味	記号	意味
R 1 隣接	d 1	(o1 R1 o2)	d33	(o17 R2 o16)
R 2 ~の前	d 2	(o1 R4 o3)	d34	(o18 R4 o3)
R 3 ~の後ろ	d 3	(o1 R5 o4)	d35	(o18 R3 o16)
R 4 ~の上	d 4	(o2 R4 o3)	d36	(o19 R4 o16)
R 5 ~の下	d 5	(o2 R4 o3)	d37	(o19 R1 o1)
	d 6	(o5 R1 o2)	d38	(o20 R5 o22)
	d 7	(o5 R4 o6)	d39	(o20 R4 o3)
	d 8	(o6 R4 o3)	d40	(o21 R1 o1)
	d 9	(o6 R1 o2)	d41	(o21 R4 o3)
	d10	(o7 R2 o6)	d42	(o22 R4 o20)
	d11	(o7 R4 o3)	d43	(o22 R1 o2)
	d12	(o8 R1 o1)	d44	(o23 R5 o22)
	d13	(o8 R4 o3)	d45	(o23 R1 o2)
	d14	(o9 R1 o1)	d46	(o23 R4 o3)
	d15	(o9 R1 o1)	d47	(o24 R4 o23)
	d16	(o10 R4 o3)	d48	(o24 R1 o1)
	d17	(o10 R1 o4)	d49	(o25 R1 o2)
	d18	(o11 R4 o3)	d50	(o25 R4 o27)
	d19	(o11 R5 o12)	d51	(o26 R1 o1)
	d20	(o11 R1 o2)	d52	(o26 R4 o27)
	d21	(o12 R4 o9)	d53	(o27 R1 o1)
	d22	(o12 R1 o1)	d54	(o27 R1 o2)
	d23	(o13 R1 o2)	d55	(o27 R4 o3)
	d24	(o13 R4 o3)	d56	(o28 R1 o1)
	d25	(o14 R5 o4)	d57	(o28 R4 o26)
	d26	(o14 R4 o13)	d58	(o28 R4 o27)
	d27	(o15 R5 o14)	d59	(o29 R4 o3)
	d28	(o15 R1 o1)	d60	(o29 R1 o2)
	d29	(o16 R4 o3)	d61	(o29 R5 o5)
	d30	(o16 R2 o1)	d62	(o30 R1 o1)
	d31	(o16 R2 o2)	d63	(o30 R4 o3)
	d32	(o17 R4 o3)	d64	(o30 R5 o4)

ば、研究室にある机は、部屋の右側にあり、形状は多様型であり、その表面の様子は無地である。同様に、30 の対象に対して学習例を作成し、瞬時学習法により学習させた後にモジュールを構成した。第2モジュールは対象間の関係を表現するための2層ネットワークモジュールである。ユニット構成は、入力層に第1モジュールの内包的知識アトムユニットと、各スキーマにおいて認められる対象間の関係を表現するユニットを、出力層に対象間の関係を表現する外延的知識アトムユニットを配置する。本事例においては、関係情報を隣接、前後および上下に限定したが、内部および外部、同種など関係情報の拡張は、必要に応じたユニットを配置することで可能になる。第1モジュールと同様に、64 の概念に対応した学習例を構成し、瞬時学習法により学習させた後にモジュールを構成した。第3モジュールは第2モジュールの知識アトムにより各スキーマを表現する。ユニット構成は、入力層には第1モジュールおよび第2モジュールの出力層にある知識アトムユニットを、出力層にはスキーマに対応するユニットを配置する。両者の知識アトムの連言とスキーマの関係に基づいた結合関係を表す学習例を構成し、瞬時学習法により学習させた後にモジュールを構成した。第4モジュールは第3モジュールのスキーマの組合せにより上位スキーマを表現するモジュールである。ユニット構成は、入力層には第3モジュールの出力層にあるスキーマに対応するユニットを、出力層には上位スキーマに対応するユニットを出力層に配置する。本事例では、8種類のスキーマに対して3種類の上位スキーマが対応する。例えば、事務所には研究室、コンピュータールーム、トイレの3つのスキーマが含まれる。これを知識アトムの連言形式に基づいた学習例として構成し、瞬時学習法により学習させた後にモジュールを構成する。

5.3 スキーマの並列探索

先の4つのネットワークモジュールは、構造化された多層ネットワークとして結合される。最下層は属性および属性値ユニットから構成される特徴ユニット、最上層は上位スキーマユニットがそれぞれ対応している。構造化された

表 4(a) ユニット相互の対応関係 (その1)

特徴ユニットと内包的知識アトムユニットの対応関係

Table 4(a) Knowledge for the 1st network module.

 o_i ($i=1, 2, \dots, 30$): 内包的知識アトムユニット, c_j ($j=1, 2, \dots, 13$): 特徴ユニット

	c1	c2	c3	c4	c5	c6	c7	c8	c9	c10	c11	c12	c13
o1 壁-1	1	0	0	0	0	1	0	0	0	0	0	0	1
o2 壁-2	0	1	0	0	0	1	0	0	0	0	0	0	1
o3 床	0	0	0	1	0	0	0	0	0	0	0	0	0
o4 天井	0	0	0	0	1	0	0	0	0	0	0	1	0
o5 窓-1	1	0	0	0	0	1	0	0	0	0	0	1	0
o6 机-1	1	0	0	0	0	1	0	0	0	0	0	0	1
o7 椅子	1	0	0	0	0	0	0	0	1	0	0	1	0
o8 本棚	0	1	0	0	0	0	0	0	1	0	0	1	0
o9 ドア	0	1	0	0	0	0	0	0	1	0	0	1	0
o10 テレビ	1	0	0	0	0	1	0	0	0	0	0	1	0
o11 ソファ	0	1	0	0	0	0	0	0	1	0	0	0	1
o12 窓-2	0	1	0	0	0	1	0	0	0	0	0	1	0
o13 浴槽	1	0	0	0	0	1	0	0	0	0	0	1	0
o14 シャワ	1	0	0	0	0	0	0	0	1	0	0	0	1
o15 換気扇-1	0	1	0	0	0	1	0	0	0	0	0	0	1
o16 テーブル	0	0	1	0	0	0	1	0	0	0	0	1	0
o17 腰掛け-1	0	1	0	0	0	0	0	0	1	0	0	0	1
o18 腰掛け-2	1	0	0	0	0	0	0	0	1	0	0	0	1
o19 窓-3	0	1	0	0	0	0	0	1	0	0	0	1	0
o20 流し台	1	0	0	0	0	1	0	0	0	0	0	1	0
o21 冷蔵庫	0	1	0	0	0	1	0	0	0	0	0	1	0
o22 換気扇-2	1	0	0	0	0	1	0	0	0	0	0	0	1
o23 便器	1	0	0	0	0	0	1	0	0	0	0	1	0
o24 洗面台	0	1	0	0	0	0	0	0	1	0	0	1	0
o25 コンピュータ	1	0	0	0	0	0	0	0	1	0	0	0	1
o26 プリンタ	0	1	0	0	0	0	0	0	1	0	0	0	1
o27 机-2	0	0	1	0	0	1	0	0	0	0	0	0	1
o28 エアコン	0	1	0	0	0	1	0	0	0	0	0	0	1
o29 ベッド	1	0	0	0	0	1	0	0	0	0	0	0	1
o30 スタンド	0	1	0	0	0	0	0	0	1	0	0	0	1

多層ネットワークにおいては、スキーマおよび上位スキーマを想起する過程を実現するために、以下のとおりの並列探索法を採用する。まず、部屋の情景の細部を想起するために部屋を構成する対象について第1モジュールを利用して個々に導出する。導出した結果は

内包的知識アトムとして一時的に結果を蓄積するためのバッファに蓄積される。導出された内包的アトム間の関係については、外部から与える必要がある。オブジェクト間の位置関係について、学習により自動的に獲得する方法の確立は、今後の課題である。導出され

表 4(b) ユニット相互の対応関係 (その2)
外延的知識アトムとスキーマの対応関係

Table 4(b) Knowledge for the 3rd network module.
S1: 研究室, S2: 居間, S3: 浴室, S4: レストラン, S5: 台所, S6:
トイレ, S7: コンピュータールーム, S8: 寝室
 d_i ($i=1, 2, \dots, 64$): 外延的知識を表す知識アトム (表 4.4 (その2))

スキーマ	外延的知識の連言
S1	$d_6 \wedge d_7 \wedge d_8 \wedge d_9 \wedge d_{10} \wedge d_{11} \wedge d_{12} \wedge d_{13} \wedge d_{14} \wedge d_{15}$
S2	$d_{14} \wedge d_{15} \wedge d_{16} \wedge d_{17} \wedge d_{18} \wedge d_{19} \wedge d_{20} \wedge d_{21} \wedge d_{22}$
S3	$d_{14} \wedge d_{15} \wedge d_{23} \wedge d_{24} \wedge d_{25} \wedge d_{26} \wedge d_{27} \wedge d_{28}$
S4	$d_{29} \wedge d_{30} \wedge d_{31} \wedge d_{32} \wedge d_{33} \wedge d_{34} \wedge d_{35} \wedge d_{36} \wedge d_{37}$
S5	$d_{38} \wedge d_{39} \wedge d_{40} \wedge d_{41} \wedge d_{42} \wedge d_{43}$
S6	$d_{42} \wedge d_{43} \wedge d_{44} \wedge d_{45} \wedge d_{46} \wedge d_{47} \wedge d_{48}$
S7	$d_{49} \wedge d_{50} \wedge d_{51} \wedge d_{52} \wedge d_{53} \wedge d_{54} \wedge d_{55} \wedge d_{56} \wedge d_{57} \wedge d_{58}$
S8	$d_6 \wedge d_7 \wedge d_{59} \wedge d_{60} \wedge d_{61} \wedge d_{62} \wedge d_{63} \wedge d_{64}$

表 4(c) ユニット相互の対応関係 (その3)
スキーマと上位スキーマとの対応関係

Table 4(c) Knowledge for the 4th network module.
SS1: 事務所, SS2: アパート, SS3: ホテル

上位スキーマ	スキーマの連言
SS1	$S_1 \wedge S_6 \wedge S_7$
SS2	$S_2 \wedge S_3 \wedge S_5 \wedge S_6 \wedge S_9$
SS3	$S_3 \wedge S_4 \wedge S_6 \wedge S_8$

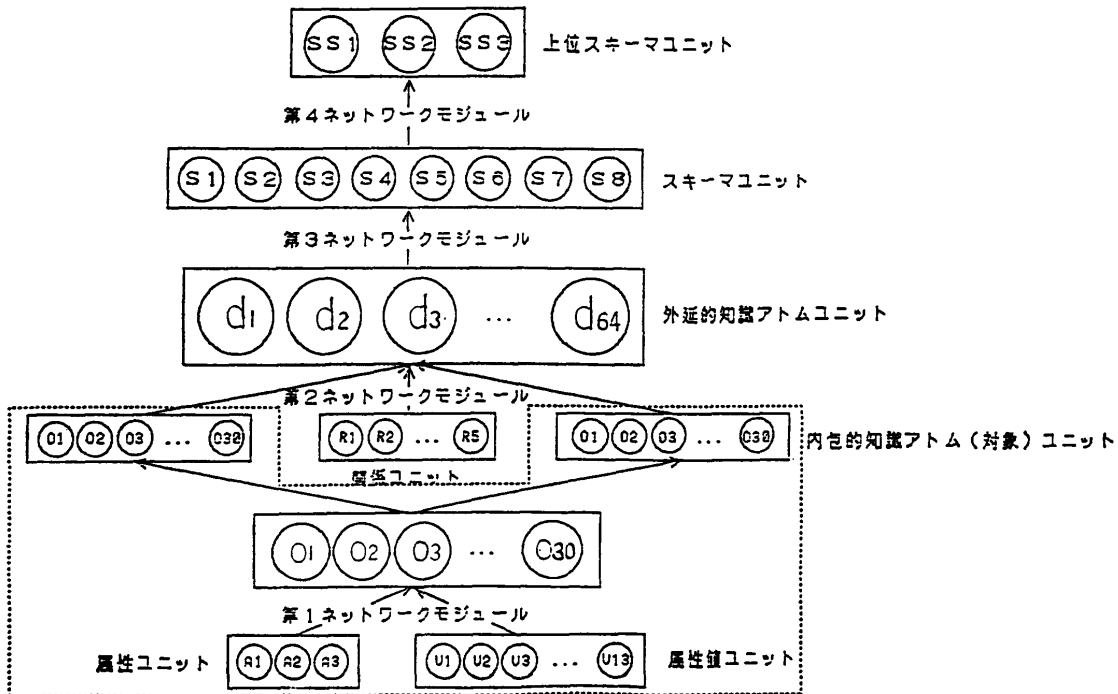


図 5 スキーマ表現のための並列推論ネットワーク
Fig. 5 Parallel inference network for representing schema.

表 5(a) 第1モジュールの推論

Table 5(a) Inference by the 1st network module.

(c_i ($i=1, 2, \dots, 13$): 特徴ユニット, o_j ($j=1, 2, \dots, 30$): 内包的知識アトムユニット)

入 力	出 力
	o_2 o_6 o_{22} o_{29}
$c_1 \wedge c_6 \wedge c_{13}$	0.6 0.6 0.6 0.6
	o_1 o_{15} o_{28}
$c_2 \wedge c_6 \wedge c_{13}$	0.7 0.7 0.7
	o_5 o_{10} o_{13} o_{20}
$c_1 \wedge c_6 \wedge c_{12}$	0.6 0.6 0.6 0.6
	o_7
$c_1 \wedge c_{10} \wedge c_{12}$	0.9
	o_8 o_9 o_{24}
$c_2 \wedge c_9 \wedge c_{12}$	0.7 0.7 0.7

表 5(b) 第2モジュールの推論

Table 5(b) Inference by the 2nd network module.

(o_j ($j=1, 2, \dots, 30$): 内包的知識アトムユニット, r_k ($k=1, 2, \dots, 5$): 関係ユニット, d_l ($l=1, 2, \dots, 64$): 外延的知識アトムユニット)

入 力	出 力
	d_6 d_{23}
$(o_5 \wedge o_{10} \wedge o_{13} \wedge o_{20}) \wedge r_1 \wedge (o_2 \wedge o_6 \wedge o_{22} \wedge o_{29})$	1.0 1.0
	d_{12} d_{14} d_{48}
$(o_8 \wedge o_9 \wedge o_{24}) \wedge r_1 \wedge (o_1 \wedge o_{15} \wedge o_{28})$	1.0 1.0 1.0
	d_{13} d_{15} d_{46} d_{47}
$(o_3 \wedge o_9 \wedge o_{24}) \wedge r_4$	0.6 0.6 0.6 0.6

表 5(c) 第3モジュールの推論

Table 5(c) Inference by the 3rd network module.

(d_l ($l=1, 2, \dots, 64$): 外延的知識アトムユニット, S_m ($m=1, 2, \dots, 8$): スキーマ)

入 力	出 力							
	S1	S2	S3	S4	S5	S6	S7	S8
$d_6 \wedge d_{23}$	0.6	0.0	0.8	0.0	0.0	0.0	0.0	0.0
$d_{12} \wedge d_{14} \wedge d_{48}$	1.0	0.0	0.0	0.0	0.0	0.6	0.0	0.0
$d_{13} \wedge d_{15} \wedge d_{46} \wedge d_{47}$	1.0	0.0	0.0	0.0	0.0	0.9	0.0	0.0

た複数のオブジェクトと、それらの関係を用いて外延的知識アトムを表現する。第2モジュールが導出した結果を外延的知識アトムとして再びバッファに蓄積し、それに基づいてスキーマを導出する。スキーマから上位スキーマの導出はこれまでと同様にバッファを利用して結果を蓄積しておくことで実行される。知識

アトム、スキーマおよび上位スキーマの導出は入出力層間の活性パターンの並列伝播により行われる。各ネットワークモジュール間の情報伝播はバッファを利用して一時的に導出結果を蓄積することによって実行される。

各モジュールでシミュレーションを行った結果を表

表 5(d) 第4モジュールの推論
Table 5(d) Inference by the 4th network module.

入 力	出 力		
	SS1	SS2	SS3
S1 ∧ S6 ∧ S7	0.1	0.0	0.0
S2 ∧ S3 ∧ S5 ∧ S6 ∧ S8	0.0	1.0	0.0
S3 ∧ S4 ∧ S6 ∧ S8	0.0	0.0	1.0

入 力	出 力		
	SS1	SS2	SS3
S6	0.4	0.2	0.3
S1 ∧ S3	0.7	0.2	0.2
S1 ∧ S6	0.9	0.0	0.0
S3 ∧ S5 ∧ S6	0.0	0.9	0.0

入 力	出 力		
	SS1	SS2	SS3
S1 ∧ S2 ∧ S5 ∧ S6 ∧ S7	1.0	0.9	0.0

5に示した。検証は各モジュールの入力情報に基づいた推論結果の妥当性を判断することによって行う。以下説明するのは第4モジュールについてであるが、第1から第3モジュールにおいても同様の議論を行える。

第4モジュールはスキーマの組合せから上位スキーマを導出するためのモジュールである。まず望ましい上位スキーマの結果に対して、スキーマの完全な組合せを与えた場合には、モジュールは正確に上位スキーマを導出できることが確認できる。不完全な組合せに対する推論に関しては、単一のスキーマを入力した場合と、不完全なスキーマの組合せを入力した場合を検証した。単一スキーマの場合、3つの上位スキーマに共通のトイレのスキーマのみを入力した場合には、上位スキーマの出力値に大小が現れる。また、アパートとホテルが共有する寝室のスキーマのみを入力した場合には、アパートとホテルでの出力値に極端な差が出た。単一スキーマの入力に対しては、そのスキーマが上位スキーマに対して持つ重みがあるまま出力値の大小となる。一方、不完全なスキーマの組合せにおいては、例えば、ホテルを想定して浴室、レストランおよびトイレを入力したときには、寝室が足りなくても、正確にホテルを導出した。同様にして、アパートを想定して浴室、台所およびトイレを入力したときには、

居間と寝室が足りないが、正確にアパートを導出することができた。

さらに、研究室、居間、台所、トイレおよびコンピュータールームの組合せのように、第4モジュールが学習していない上位スキーマに関する情報を入力した場合には、それに類似した上位スキーマを結論として導出することがわかった（この場合、事務所とアパートを想起した）。これにより、知識として獲得されていない情報に対してもユニット間の結合関係および結合係数に基づいて、類推的な想起を実行できることがわかる。

6. 結 論

本論文は、複雑な構造を持つ知識をコネクショニスト記号処理モデルにより表現し利用するための新たなネットワークアーキテクチャである並列推論ネットワークとその学習戦略である瞬時学習法を提案した。並列推論ネットワークは、2層ネットワークモジュールを必要とする入出力関係に対して構成し、それを統合することによって多層型のネットワークを構成する。それによって、モジュールにおける超並列的な情報処理と複雑な構造を持つ知識の表現が同時に可能になる。瞬時学習法はネットワークモジュールの学習戦略として、これまでの誤差逆伝播法とは違いネットワークの汎化能力を向上させ、ネットワーク学習に要する時間を極端に短縮することができる。この新たなアプローチにより、これまでのコネクショニスト記号処理モデルの弱点であった知識構造の表現および利用を解決することができることを確認した。

今後の研究方向としては、知識情報処理システムの実現、強力な汎化能力を利用して自己の導出した結果に基づくモデルの自己組織化（学習例の自動構成、メタ学習）能力の研究などに応用することを考えている。

参 考 文 献

- 1) Barnden, L. : Complex Cognitive Information-Processing: A Computational Architecture with a Connectionist Implementation, TR-211, Indiana University (1986).
- 2) Bartlett, F. C. : *Remembering*, Cambridge University Press (1932).
- 3) Baum, E. M. and Hausser, D. : What Size Net Gives Valid Generalization?, *Neural Comput.*, Vol. 1, pp. 151-160 (1989).
- 4) Brown, L. E. and Kulik, J. : Flushbulb Memo-

- ries, *Cognition*, Vol. 5, pp. 73-99 (1977).
- 5) Fanty, M. A.: *Learning in Structured Connectionist Networks*, TR-252, University of Rochester (1986).
 - 6) Fahlman, S. E.: *NETL: A System for Representing and Using Real-World Knowledge*, MIT Press (1979).
 - 7) Feldman, J. A.: *Dynamic Connections in Neural Networks*, *Biol. Cybernetics*, Vol. 46, pp. 27-39 (1982).
 - 8) Feldman, J. A.: *Neural Representation of Conceptual Knowledge*, TR-189, University of Rochester (1986).
 - 9) Hinton, G. E. (eds.): *Special Issue on Connectionist Symbol Processing*, *Artif. Intell.*, Vol. 46, pp. 1-105 (1990).
 - 10) Hinton, G. E.: *Mapping Part-Whole Hierarchies into Connectionist Networks*, *Artif. Intell.*, Vol. 46, pp. 47-75 (1990).
 - 11) Kohonen, T.: *Self-Organization and Associative Memory*, Springer-Verlag (1988).
 - 12) Michalski, R., Carbonell, J. and Mitchell, T.: *Machine Learning*, Vol. 1, No. 1 & 2, Morgan Kaufmann (1983).
 - 13) Namatame, A.: *A Flash Learning for Multilayer Networks*, *Proc. of IJCNN-91*, Vol. 2, pp. 53-57 (1991).
 - 14) Piaget, J.: *The Origins of Intelligence in Children*, International University Press (1952).
 - 15) Rumelhart, D. E. and McClelland, J.: *Parallel Distributed Processing*, Vol. 1 & 2, MIT Press (1986).
 - 16) Smolensky, P.: *Information Processing in Dynamical Systems: Foundations of Harmony Theory*, *Parallel Distributed Processing*, Vol. 1, MIT Press (1986).
 - 17) Steinbuch, K.: *Learning Matrices and Their Applications*, *IEEE Trans. EC-12*, pp. 846-862 (1963).
 - 18) Touretzky, D. S.: *BoltzCONS: Dynamic Symbol Structures in a Connectionist Networks*, *Artif. Intell.*, Vol. 46, pp. 5-45 (1990).
 - 19) 内田: *並列推論マシン*, *人工知能学会誌*, Vol. 2, No. 4, pp. 450-458 (1987).
 - 20) Volper, D. J. and Hampson, S. E.: *Connectionistic Models of Boolean Category Representation*, *Biol. Cybernetics*, Vol. 54, pp. 393-406 (1986).
 - 21) Waltz, D. and Feldman, J. A.: *Connectionist Model and Their Applications*, Ablex Publishing (1988).
 - 22) 山口, 樋口, 坂井: *並列型 AI マシン*, *人工知能学会誌*, Vol. 2, No. 4, pp. 459-471 (1987).


(平成3年3月18日受付)

(平成3年10月3日採録)



生天目 章 (正会員)

1973年防衛大学校卒業 (応用物理学専攻)。1979年スタンフォード大学大学院博士課程修了 (Ph. D)。同年, 航空幕僚監部勤務。1987~1988年ジョージメイソン大学客員助教授。現在, 防衛大学校情報工学教室助教授。人工知能, ニューラルネットワーク, 意志決定工学などの研究に従事。人工知能学会, 計測自動制御学会, AAAI, ACM, INNS, IEEE 各会員。



大澤 洋一

1986年防衛大学校卒業 (国際関係論専攻)。同年, 陸上自衛隊入隊。1991年, 防衛大学校理工学研究科卒業。現在陸上自衛隊第9師団勤務。