

オブジェクト指向ニューラルネットワークモデル

塚本 義明[†] 生天目 章[†]

本論文では、構造的な概念知識をニューロ情報として処理するための情報処理モデルとして、オブジェクト指向ニューラルネットワークモデルを提案する。オブジェクト指向データモデルとして概念化された知識をニューロ情報として処理するために適切なインデックス化法を導入する。また、インデックス化された概念知識をオブジェクト指向モデルに基づき体系化することにより、ニューラルネットワークの学習空間を構築する。オブジェクト指向モデルのクラス階層組織の概念を取り入れた大規模で異質なニューラルネットワークの構築法を提案する。クラス階層組織として構築されるオブジェクト指向ニューラルネットワーク学習空間の各ノードには、同質のデータ構造を持つ学習例の集合（1つのネットワークモジュール）が対応し、それらのノードを組織化することにより異質で大規模なニューラルネットワークを構築する。以上のニューロ情報の組織化モデルおよびニューロ情報の推論モデルをニューロ情報に定義されるインデックスの操作手続きとして定式化する。また、オブジェクト指向ニューラルネットワークモデルの連想データベースへの応用例について示す。

An Object-Oriented Neural Network Model

YOSHIAKI TSUKAMOTO[†] and AKIRA NAMATAME[†]

The concept of modularization and coupling neural network modules is a promising way of a building large-scale neural network model and improving the learning performance of these networks. On the other hand, the modularization scheme would be little use if there does not exist such an appropriate learning procedure to train high-level modules separately and to integrate those functionally pre-specified modules efficiently. This paper describes an object-oriented neural network model that realizes such a learning procedure that supports the modularization and coupling connectionist network modules. The whole network is constructed from several interacting these neural network modules.

1. はじめに

人間が行うような柔軟な情報処理や環境と相互作用するシステムを実現するために、パターン情報処理とシンボル情報処理との融合した情報処理モデルへのニーズが近年高まってきている^{2),3),6),10)}。従来の記号のパターンマッチングによる推論ではなく、より人間の感性に近い推論が求められている^{3),12)}。しかしパターン処理を主な対象としてきた従来のニューラルネットワークモデルを複雑な概念知識の表現や推論の問題に拡張していくことが重要な課題になっている¹⁴⁾。特に記号処理モデルのように、深層的な知識を推論可能にすることが大きな課題になっている。すなわち、現在のニューラルネットワークモデルは、何を推論させたいか、あるいは何を学習したいかについては、あらかじめネットワークのアーキテクチャとして構築す

るか、または学習例として与えておく必要がある。また、ニューラルネットワークモデルでは、概念（記号）の意味の扱いが不明瞭である。これらは、ニューラルネットワークモデルによる高次認知処理機能の実現には不可欠である⁵⁾。

本論文では、構造化および体系化された概念知識をニューロ情報として処理するための情報処理モデルとしてオブジェクト指向ニューラルネットワークモデルを提案する。オブジェクト指向データモデルとして概念知識をニューロ情報として処理することを可能にする適切なインデックス化法を導入する。オブジェクト指向のクラス階層概念をニューラルネットワークへ応用することで、大規模なネットワークを構築できることを示す。また、オブジェクト指向知識のクラス階層を学習空間へと変換しニューラルネットワークに学習させ、同時並列推論を実現する方法を提案する。また、オブジェクト指向の汎化と集約化の概念に基づき、それぞれ異なる型の複数の学習空間の組織化法について提案する。オブジェクト指向モデルにおけるクラス

[†] 防衛大学校情報工学教室
Department of Computer Science, National Defense Academy

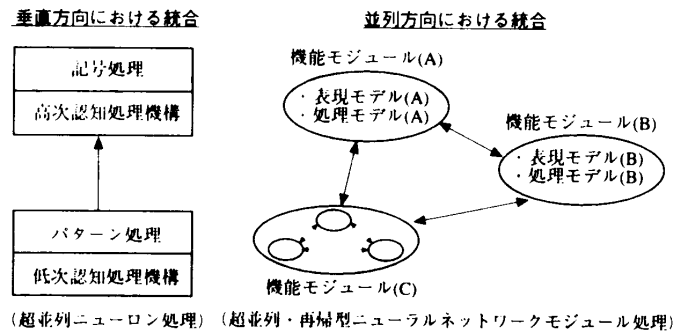


図1 記号処理とパターン処理の統合

Fig. 1 The integration symbol and pattern processing.

階層組織を構成する各ノードには、同質のデータ構造の学習例集合である学習空間が対応する。各ノードを構成する学習空間を組織化することにより、異質で大規模なニューラルネットワークを構築し、対象世界をニューロ情報として表現する。応用例として本モデルを連想データベースへ応用し、意味情報に基づく推論が可能になることを示す。

2. オブジェクト指向ニューラルネットワークによる記号処理とパターン処理の融合

我々は、対象世界と記号を対応づけることによりさまざまな処理を行っている¹⁾。しかしながら、状況依存や解釈の多義性の問題があり、これらをどのように解決するかが重要な課題である。近年解決策としてシンボルとパターンを統合し処理する研究がさかに行われている^{3),6)~8),10)}。従来の記号とパターン処理の統合においては、図1に示すようにまず低次認知処理機構であるパターン処理を行い、次に高次認知処理機構である記号処理を施す形式、すなわち垂直方向の統合方法が考えられている。従来の融合法がボトムアップ処理であるのに対し、本論文では、トップダウン処理による融合法を考える。内部モデルとして表現モデルと処理モデルを持つ機能モジュールが、相互作用し処理する形式、すなわち並列方向に統合する方法を提案する。垂直方向における統合は、パターン処理の後に記号処理が行われるために記号とパターンの意味が不明瞭となる欠点がある。並列方向における統合においては、それぞれの機能モジュールが表現モデルと処理モデルを内在化しているので記号とパターン間の意味がとらえやすいという特徴がある。また、記号処理に基づく認知機能の研究⁹⁾やニューラルネットワークに基づく認知機能研究¹⁾において、人間はスキーマと呼ばれる、いわば多くのテンプレートを内在化させ、それらのテンプレートに基づいて対象世界におけるさまざまな事物を観察することが知られている。つまり、

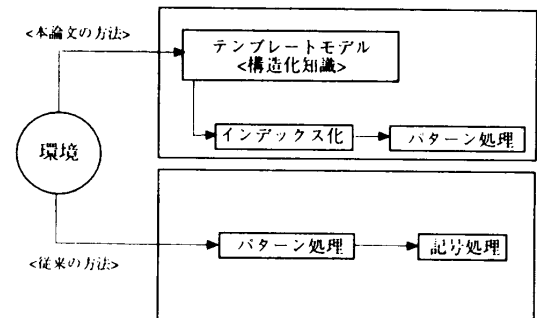


図2 テンプレートに基づくパターン処理と記号処理の融合
Fig. 2 The hybrid model of pattern and symbol processing with templates.

自分の興味のある対象をテンプレートに基づいてある枠組みの中で環境から抽出し、テンプレートによって抽出された構造化情報で知識処理するという考えに基づくものである。テンプレートとは、対象世界を観察するための枠組みで、それは構造化知識として適切に記述することができる。すなわち、我々の認識はボトムアップ的な処理だけでなく、構造化された知識の枠組みに基づき、トップダウン的な処理にも依存していると考えられる。図2に示すように、テンプレートに基づき対象世界を観察し、概念化された知識をインデックス化し、それをパターン処理する方法により、記号処理とパターン処理の融合法を提案する。以上のテンプレートをオブジェクト指向モデルの概念に基づき表現する。オブジェクト指向モデルは、数多く考察された記号表現モデルの統一された表現モデルとして位置づけられ、また知識の抽象化・組織化(汎化・集約化)が容易で、属性の継承による知識の組織化や推論が可能である⁴⁾。

オブジェクト指向ニューラルネットワークモデルの概念図を図3に示す。オブジェクト指向データモデルとして概念化された知識をニューロ情報として処理するために適切なインデックス化法を導入する。また、インデックス化された概念知識をオブジェクト指

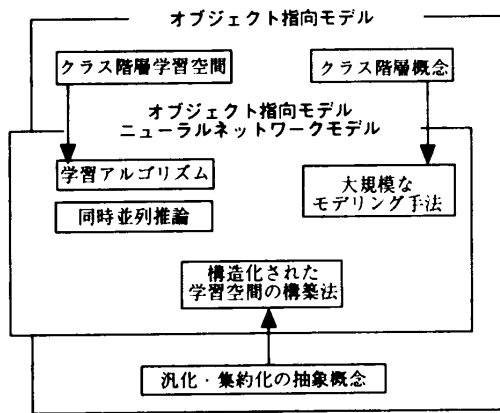


図3 オブジェクト指向ニューラルネットワークの概念図

Fig. 3 A conceptual framework of the object-oriented neural network model.

向モデルに基づき体系化することにより、ニューラルネットワークの学習空間を構築する。オブジェクト指向モデルのクラス階層組織の概念を取り入れた大規模で異質なニューラルネットワークの構築法を提案する。クラス階層組織として構築されるオブジェクト指向ニューラルネットワーク学習空間の各ノードには、同質のデータ構造を持つ学習例の集合（1つのネットワークモジュール）が対応し、それらのノードを組織化することにより異質で大規模なニューラルネットワークを構築する。オブジェクト指向モデルに基づく大規模で構造化された学習空間の構築法は、4章で詳細に示す。以上のニューロ情報の組織化モデルおよびニューロ情報の推論モデルをニューロ情報に定義されるインデックスの操作手続きとして定式化する。実装モデルとして、個々の階層型情報を特徴づける要素や推論のための手続き等をオブジェクトとしてカプセル化し、各ノードのメッセージのやりとりによって推論を行うオブジェクトモデルとして実装する。オブジェクトとして定義されるニューロ情報は、推論に必要なパラメータおよび手続きを内部に保持し、推論の際にはメッセージに応じた処理をそれ自身が実行し判断する。また、その推論は、同時並列的な推論である。

3. オブジェクト指向知識のインデックス化

本章においては、オブジェクト指向モデルとして概念化された知識のインデックス化方法について示す。

3.1 オブジェクト指向モデルの概念

オブジェクト指向モデルにおいて、汎化とは、いくつかのオブジェクトが持つ共通的な性質に着目し、その共通的な性質を持つより一般化されたクラスを定義する考え方で、汎化の逆を特殊化という¹³⁾。汎化と特殊化の関係のあるクラスをそれぞれ上位クラス、下位

クラスとよび、このような上位、下位クラス関係をクラス階層と定義する。クラス階層と集約化の混在したクラスの構成法を一般に抽象化によるモデリングと定義される。上位、下位関係として定義されるクラス階層関係は、推移的である。また、上位・下位クラス関係によって定義されるクラス階層組織は、クラスを構成要素の集合と見なすことにより集合の包含関係として表現できる。クラス階層関係を記号 \prec で表現すると、ある2つのクラス X , Y 間のクラス階層関係は要素（インスタンス）の集合 X , Y 間の包含関係としても表現できる。

$$X \prec Y \rightarrow Y \subset X \quad (1)$$

すなわち、クラス間に階層組織が定義できる場合には、さらに継承という概念が定義できる。継承とは、上位のクラス Y に属する各要素が持つ性質は、下位のクラス X に属する要素をも共通して持つとする考え方である。これは下位のクラス X の要素は、その上位のクラス Y の要素でもあるという X および Y の集合間の包含関係に立脚した考え方である。

以下にクラス階層（クラススキーマ）の定義を与える。クラス C を属性 A_i およびその定義域 $Dom(A_i)$ の集合として

$$C = \{A_1 : Dom(A_1), A_2 : Dom(A_2), \dots, A_n : Dom(A_n)\} \quad (2)$$

で定義する。ここで、属性 A_i の定義域 $Dom(A_i)$ が他のオブジェクトのクラス C_j である場合に、クラス C を特に複合クラスと呼ぶ。一般にクラスの集合 $S = \{C_1, C_2, \dots, C_k\}$ の要素 C_i, C_j には、集合の包含関係に基づく上位または下位関係

$$C_i \prec C_j \text{ or } C_j \prec C_i \quad (3)$$

が定義できる。式(2)で定義したクラスをノードとし、ノード間に定義される有向リンクとともに定義される有向グラフをクラス・スキーマと定義する。

3.2 知識オブジェクトのインデックス化

クラス $C = \{A_1 : Dom(A_1), A_2 : Dom(A_2), \dots, A_n : Dom(A_n)\}$ が生成するインスタンス（知識オブジェクト）を

$$[(\text{クラス情報}) (\text{属性情報})] \quad (4)$$

の2対1組の記号情報として記述する。ここで属性情報は、属性空間 $A = A_1 \times A_2 \times \dots \times A_n$ の要素である。記号（シンボル）表現されたクラス情報および属性情報をビットコードでインデックス化し、それぞれクラスコードおよび属性コードと定義する。また、インデックス化された知識オブジェクトを、以下ニューロ情報オブジェクトと呼ぶことにする。

クラス C_j のニューロ情報オブジェクト O_j の属

性 A_k の属性コードをビットベクトル $\psi_{A_k}(O_i)$ で表す。また、ニューロ情報オブジェクトのクラスコードを $\varphi_{C_j}(O_i)$ で表し、次式で定義する。

$$\varphi_{C_j}(O_i) = (c_j, r_{ji}, \bar{c}_j, \bar{r}_{ji}) \quad (5)$$

ここで、

- c_j : クラス C_j のクラスコード
- r_{ji} : O_i のクラス C_j におけるコード
- \bar{c}_j : O_i の上位ニューロ情報オブジェクトのクラスコード
- \bar{r}_{ji} : O_i の上位ニューロ情報オブジェクトのインスタンスコード

である。ここで、上位クラスからの継承されるコードを

$$\bar{\varphi}_{C_j}(O_i) = (\bar{c}_j, \bar{r}_{ji}) \quad (6)$$

で記述する。以下に O_i のクラスコード c_j の求め方を示す。

Step 1.1 k 個のクラスの集合 $S = C_1, C_2, \dots, C_k$ に対し、それぞれのクラスを局所表現する。すなわち、 i 番目のクラス C_i に対し、 i 番目のビットが1で他が0となる k ビットコード c_j を付与する。

Step 1.2 次に各クラスの継承クラスコードを以下の方法により再帰的に付与する。 $C_i \prec C_j$ の関係があるクラス C_i に対しクラス C_j のクラスコード c_j を継承させ、自己のクラスコード c_j との論理和演算をとってクラス C_i の新しいクラスコード c_i とする。すなわち、

$$c_j := c_j \oplus c_i \quad (7)$$

ここで、 \oplus は論理和演算を表す。□

このようなクラスコードに対して、以下のような性質が成立する。

$$\begin{aligned} C_i \succ C_j &\Rightarrow c_i \otimes c_j = c_j \\ C_i \prec C_j &\Rightarrow c_i \otimes c_j = c_i \end{aligned} \quad (8)$$

ここで、 \otimes は論理和演算を表す。

インスタンスコード r_{ji} は、クラスコードの生成法と同様にクラス C_j の k 個のインスタンスに対し、それぞれのニューロ情報オブジェクトを局所表現する。以上のような識別コードにより、下位関係にあるクラス C_a のニューロ情報オブジェクトは、上位の関係にあるクラス C_b のニューロ情報オブジェクトの継承インスタンスコードとして継承される。すなわち、それぞれに属する同じニューロ情報オブジェクトのそれぞれにおけるクラスコードは、

$$\varphi_{C_a}(O_i) = (c_a, r_{ai}, \bar{c}_a, \bar{r}_{ai}) \quad (9)$$

$$\varphi_{C_b}(O_i) = (c_b, r_{bi}, \bar{c}_b, \bar{r}_{bi}) \quad (10)$$

で定義されるので、異なるクラスに属するニューロ情報オブジェクトは同じインスタンス継承コードが付与される。また、ルートとなるニューロ情報オブジェクトのインスタンス継承コードは、

$$\bar{\varphi}_{C_j}(O_i) = (c_j, r_{ji}) \quad (11)$$

と定義する。属性 A_k があるクラス C_j となる場合には、その属性コード $\psi_{A_k}(O_i)$ は、

$$\psi_{A_k}(O_i) = (c_j, r_{ji}) \quad (12)$$

として定義する。

以上、知識のオブジェクト化について抽象的に記述してきたが、具体的な手順については6章での適用例において詳細に示す。

4. オブジェクト指向ニューラルネットワークの学習空間の構築法

本章では、オブジェクト指向ニューラルネットワークの学習空間の構築法について示す。オブジェクト指向モデルによるニューラルネットワークの構築法とは、ニューロ情報の特性ベクトルの集合を、オブジェクト指向の汎化と集約化の概念に基づいて組織化する方法である。オブジェクト指向モデルにおいて、オブジェクトが、他のいくつかのオブジェクトから構成される時、このオブジェクトは、構成要素である他のオブジェクトの集約化によって定義される。集約化によって表現されるオブジェクトを複合オブジェクトと定義する。

クラス階層の組織化手順として大きく分けてボトムアップ・アプローチおよびトップダウン・アプローチの2つが考えられる。ボトムアップ・アプローチは、個々のインスタンスの集合であるクラスをあらかじめ構築しておき、関連する複数のクラスを統合することにより、より上位のオブジェクトのクラスを構築していくアプローチである。クラスの統合によって構築されたオブジェクトのクラスは、さらに上位のオブジェクトのクラスを表すための部品となる。一方、トップダウン・アプローチは、まず表現しようとする体系の大枠を決め、大枠を構成する構成要素の中に、その概念の詳細を表す下位クラスを記述していくアプローチである。以下では、次のようなオブジェクト指向の集約化と汎化に基づく組織化手順を取り入れたオブジェクト指向ニューラルネットワークの学習空間の構築法について示す。

(1) 上位クラスの生成 (ボトムアップによるアプローチ)

複数のクラスに共通する属性を求め、それを上位クラスの属性情報とする。下位クラスに属す

るインスタンスは生成された上位クラスのインスタンスになる。

(2) 下位クラスの生成 (トップダウンによるアプローチ)

新たに属性情報を付加することにより、クラスをいくつかに分細化し、分類されたクラスを新たに下位クラスとして定義する。

ニューラルネットワークモデルにおける集約化の概念は、以下のように定義できる。すなわち、ニューロ情報の属性情報が積属性として定義されるとき、それぞれの属性ごとに小規模なネットワークを構築し全体の積属性空間はそれらを構成要素と統合する。一方、汎化とはいくつかのオブジェクトが持つ共通的な性質に着目し、その共通的な性質を持つより一般化されたクラスを定義する考え方である。ニューラルネットワークにおける汎化は、複数のニューラルネットワークの学習例の中で共通の属性を持つニューロ情報を抽出し、それらの共通するニューロ情報の集合として新たなクラス (ニューラルネットワークモジュールの学習空間) を構築することである。

一般に式 (4) のニューロ情報のクラス情報および属性情報は積空間として定義されることから、式 (5) で定義したニューロ情報 O_i の特性ベクトルの定義を積空間上に拡張する。ニューロ情報 O_i の属性積空間 $F = A_1 \times A_2 \times \dots \times A_m$ における属性ベクトルをそれぞれの属性 A_k の属性ベクトル $\psi_{A_k}(O_i)$ の積ベクトル

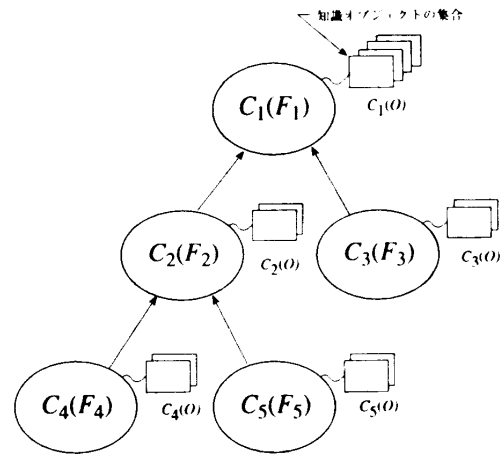
$$\psi_A(O_i) = (\psi_{A_1}(O_i), \psi_{A_2}(O_i), \dots, \psi_{A_m}(O_i)) \tag{13}$$

として定義する。

オブジェクト指向の汎化と集約化の概念に基づくオブジェクト指向ニューラルネットワークの学習空間の構築法について、図 4 の例を用いて以下に示す。 F_i は、式 (13) で定義した属性積空間である。上位のクラスとして定義される C_1 の属性空間は、下位クラスとして定義される C_2, C_3 の共通な属性の属性積空間として定義できる。一般に、ニューロ情報の上位クラス C_i の属性積空間 F_i は、その下位クラス C_j の属性積空間 F_j の共通空間として次式で定義する。

$$F_i = \bigwedge_{C_j \prec C_i} F_j \tag{14}$$

以上のことを一般化すると次のようになる。属性ごとの学習空間 $\{\{\psi_{A_k}(O_i), \varphi_C(O_i)\} : O_i, k = 1, 2, \dots, m\}$ を求め、それを用いて属性積空間 $F = A_1 \times A_2 \times \dots \times A_m$ 上に定義される学習空間 $\{\{\psi_A(O_i), \varphi_C(O_i)\}\}$ を構築する。また、上位クラス



C_i : 知識オブジェクトのクラス C ,
 F_i : 知識オブジェクトのクラス C_i の属性積空間
 $C_i(O)$: クラス C_i に含まれる知識オブジェクトの集合

図 4 オブジェクト指向ニューラルネットワークの学習空間の構築法
 Fig. 4 A product of learning example space with the object-oriented neural network.

C_i のニューロオブジェクトの集合には、下位クラス C_j に含まれるのニューロオブジェクトも含まれる。すなわち、

$$C_j \prec C_i \Rightarrow C_j(O) \subset C_i(O) \tag{15}$$

である。オブジェクト指向ニューラルネットワークの学習空間の構築とは、式 (14) および式 (15) の性質を利用することにより、ニューロ情報の各クラスのニューロ情報オブジェクトに対して、式 (13) の特性ベクトルの集合を求めることである。

5. ニューロ情報の推論モデル

ニューロ情報 O_1 の属性情報の集合を $P_1 \subseteq F_1$, ニューロ情報 O_2 の属性情報の集合 $P_2 \subseteq F_2$ の間に集合の包含関係、

$$P_1 \supset P_2 \tag{16}$$

が成立する場合、ニューロ情報 O_1 はニューロ情報 O_2 の下位の関係にあると定義し、 $O_1 \prec O_2$ と記述する。あるニューロ情報をその属性情報から推論するにあたっては、ニューロ情報を特徴づける属性情報の集合の部分集合 (すなわち内包関係にあるすべての集合) からそのニューロ情報を推論できるようにする必要がある。すなわち、上記の例においては属性情報の集合 P_2 を有するニューロ情報としてニューロ情報 O_1 だけでなく O_2 をも同時に推論できるように設計する必要がある。本章では、属性情報の集合の間に定義される包含関係に基づく記号処理の逐次推論法について示し、次にニューロ情報の並列推論法について示す。

5.1 構造化知識の記号処理による推論法

記号表現された式 (2) のオブジェクト指向データに対し、以下のように上位および下位関係を定義する。

- (1) 原子型 (クラス) T および T' に対して, T のオブジェクトがすべて T' に含まれるとき, T を T' の部分型 (部分クラス) と定義し $T \prec T'$ で表す。
- (2) タプル型 $T : (T_1, T_2, \dots, T_n)$ および $T' : (T'_1, T'_2, \dots, T'_n)$ に対し, $T_i \prec T'_i$ のとき $T \prec T'$ で表す。
- (3) 集合型 $T : \{S\}$ および $T' : \{S'\}$ に対し $S' \supset S$ のとき $T \prec T'$ で表す。

以上の上位・下位関係を利用したタプル型 $T : (T_1, T_2, \dots, T_n)$ に対する質問形式 $Q : (Q_1, Q_2, \dots, Q_k)$ による記号処理に基づく推論法は次のような手順となる。

Step 2.1 タプル型で指定された各要素の型 Q_i に関する質問に対し、直接の上位クラスを求める。すなわち, $Q_1 \leq T'_1, Q_2 \leq T'_2, \dots, Q_k \leq T'_k$ を求める。

Step 2.2 Step 2.1 となるような $\{T'_1, T'_2, \dots, T'_m\}$ を原子型組合せを要素として持つタプル型 T を求める。

このとき $T : \{S\} \subset T'_1, T'_2, \dots, T'_m$ となる S の T に対して $Dom(T) \supset Dom(Q)$ となるので, Q を型として持つインスタンスは T の要素である。逆に, $Dom(T) \supset Dom(Q)$ となる Q に対して $Q_1 \leq T'_1, Q_2 \leq T'_2, \dots, Q_k \leq T'_k$ が成立する。

5.2 ニューロ情報の推論法

ニューロ情報クラス C_i のニューラルネットワークは、図 5 に示すようにクラス情報を学習する *Class module* および積属性情報を学習する *Attribute module* から構成される。*Attribute module* は、属性がとるニューロ情報クラスを学習する *Key module* とクラス C_i のニューロ情報オブジェクトの属性空間を学習する *Value module* から構成される。*Key module* は、属性が参照しているクラスにおける属性のコードを学習する *Class module* とその継承関係を学習する *Inheritance module* から構成される。*Value module* は、属性情報を学習する *Self module* と属性の継承を学習する *Inheritance module* から構成される。それぞれは、属性のクラスを学習する *Classcode module* と属性値を学習する *Localcode module* から構成される。本節では、それぞれのネットワークにニューロ情報のクラス情報および属性情報の同時並列型の推論法について示す。

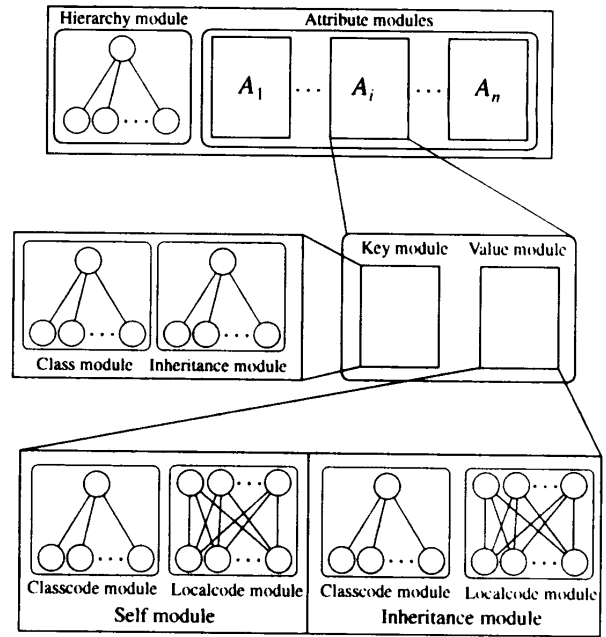


図 5 ニューロオブジェクトネットワーク構造
Fig. 5 Architecture of neuro-object networks.

5.2.1 クラス情報に基づく並列推論

ニューロ情報のクラス情報に基づく推論とは、クラススキーマの階層構造を利用するもので、あるニューロ情報のクラスの上位または下位関係にあるニューロ情報を同時並列的に求めることである。あるクラス C_i と上位関係または下位関係にあるクラス C_j を求めるための方法を以下に示す。クラス C_i における活性化関数は、式 (5) において定義したニューロ情報オブジェクトのクラスコード $c_i, 1 \leq i \leq n$ を利用して次式で定義する。

$$F_i(c_j|c_i) = \|c_i \otimes c_j\| - \min(\|c_i\|, \|c_j\|) + \epsilon \quad (17)$$

ここで、 $0 < \epsilon < 1$ である。式 (17) は以下の性質を持つ。

- (1) $C_i \succ C_j$ のとき
 $\|c_i \otimes c_j\| = \|c_i\|$ および $\min(\|c_i\|, \|c_j\|) = \|c_i\|$ となるので
 $F_i(c_j|c_i) > 0$
- (2) $C_i \preceq C_j$ のとき
 $\|c_i \otimes c_j\| = \|c_j\|$ および $\min(\|c_i\|, \|c_j\|) = \|c_j\|$ となるので
 $F_i(c_j|c_i) > 0$
- (3) その他の場合
 $\|c_i \otimes c_j\| \leq \min(\|c_i\|, \|c_j\|)$ となるので
 $F_i(c_j|c_i) < 0$

したがって、クラス C_i は他のクラス C_j からの入力メッセージを受け取り、それと上位または下位のクラス関係がある場合だけに反応することができる。

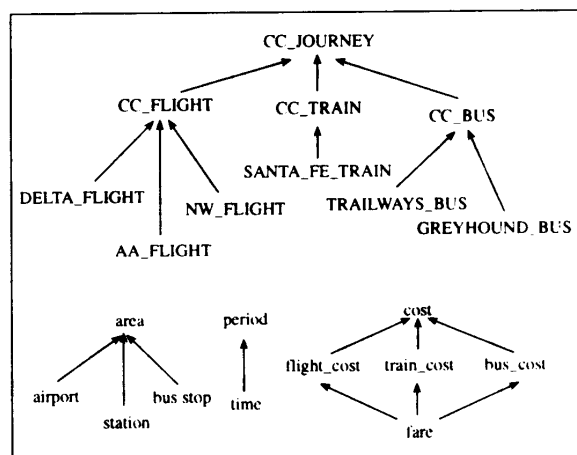
5.2.2 属性情報に基づく並列推論

本項では、属性情報に基づく推論について示す。クラス C_a が問合せメッセージ $Q = (C_{A_k}, (c_i, r_{ij}, \bar{c}_i, \bar{r}_{ij}))$ を受け取った場合は、図5に示す *Attribute modules* に入力される。 C_{A_k} が *Key module* に入力され、関係する属性であるか判定される。関係する属性であれば問合せメッセージ Q の残りの要素は、 *Self module* の *Classcode module* に c_i が、 *Localcode module* に r_{ij} が、 *Inheritance module* の *Classcode module* に \bar{c}_i が、 *Localcode module* に \bar{r}_{ij} がそれぞれ入力される。 *Classcode module* は、式(17)を活性化関数として持つので上位または下位関係が推論できる。属性 A_k のクラスコード c_k が c_i と関係あるならば、 *Self module* の *Classcode module* が発火する。さらに *Localcode module* が発火すれば、 (c_i, r_{ij}) を属性として持つことが分かる。 *Inheritance module* についても同様である。

6. 連想データベースへの適用例

リレーショナルデータベースに代表される現在のデータベースでは、データベースの内容と質問内容が正確で一貫性がなくてはならない¹¹⁾。この制約は、使用者からしてみると非常に柔軟性に欠ける。解決策として、近年連想データベース等の研究がさかんに行われ、柔軟性のある検索が可能となってきている^{4),11)}。また、現在さまざまな情報が電子化され、情報化社会の進展とともにネットワークを利用した情報の普及が行われつつある。これらの情報を多角的に活用するためには、断片的情報として蓄積するのではなく、情報間の関連性や類似性に着目し、それに基づいて関連情報を組織化することが必要である。本章においては、オ

ブジェクト指向ニューラルネットワークモデルを連想データベースの問題に適用する。ここでは、図6に示す交通手段に関するオブジェクトの集合を対象とした CC_JOURNEY (米西海岸と東海岸間の旅行データベース) オブジェクト指向知識⁴⁾ をニューロ情報として構築した。本例は、CC_JOURNEY クラスをトップクラスとして交通手段で特化したクラス構成で、それぞれのクラスの属性となるクラスも定義されている。これらのオブジェクト指向知識を組織情報と属性情報の観点からインデックス化し、そのインデックス情報から学習空間を構築し、ニューラルネットワークに学習させる。ニューラルネットワークの学習結果を用いて、従来の記号処理モデルでは困難であった並列



CC_JOURNEY(departure_area, arrival_area, duration, cost)
 CC_FLIGHT(departure_area, arrival_area, departure_period, arrival_period, flight_cost)
 CC_TRAIN(departure_area, arrival_area, departure_period, arrival_period, train_cost)
 CC_BUS(departure_area, arrival_area, departure_period, arrival_period, bus_cost)
 DELTA_FLIGHT(flight#, departure_airport, arrival_airport, departure_time, arrival_time, fare)
 AA_FLIGHT(flight#, departure_airport, arrival_airport, departure_time, arrival_time, fare)
 NW_FLIGHT(flight#, departure_airport, arrival_airport, departure_time, arrival_time, fare)
 SANTA_FE_TRAIN(train#, departure_station, arrival_station, departure_time, arrival_time, fare)
 TRAILWAYS_BUS(bus#, departure_busstop, arrival_busstop, departure_time, arrival_time, fare)
 GRAYHOUND_BUS(bus#, departure_busstop, arrival_busstop, departure_time, arrival_time, fare)

図6 オブジェクト指向知識の例

Fig. 6 An example of object-oriented knowledge.

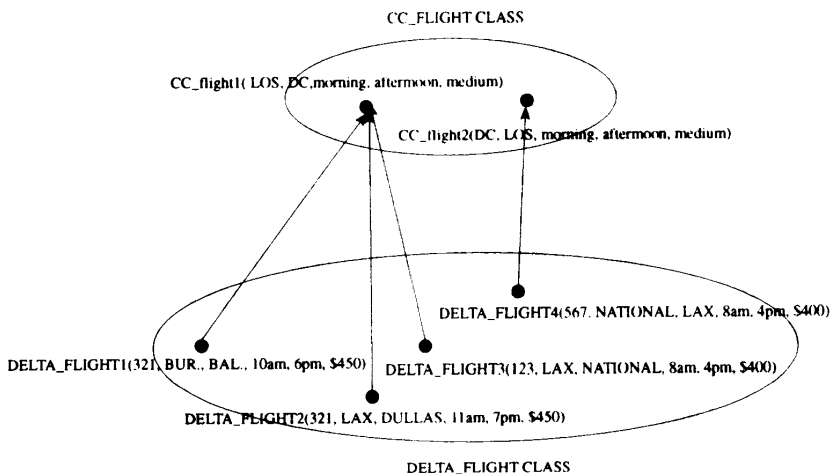


図7 CC_FLIGHT クラスにおける知識の例

Fig. 7 An example of object-oriented knowledge on CC_FLIGHT class.




図8 Areaクラスにおける知識の例

Fig. 8 An example of object-oriented knowledge on Area class.

推論，連想推論をできることを示す。

ここでは，図7に示すCC_FLIGHTクラスを例にしてインデックス化と学習空間の構築について述べる。CC_FLIGHTの属性となるAirportクラスとその上位クラスであるAreaクラスのインスタンスの関係を図8に示す。これらのクラス構造に対し，式(5)で定義したニューロ情報オブジェクトコードを表1および表2に示す。また，CC_JOURNEYクラス以下で定義されている属性コードを表3および表4に示す。それらを属性とするCC_FLIGHTクラス以下のニューロ情報オブジェクトコードを表5に示す。ニューロ情報オブジェクトコードとインスタンスの上下関係を表す学習空間は同様にして構築できる。表6および表7に示す属性学習空間の入力パターンとしては，それぞれ属性と定義されたクラスのニューロ情報オブジェクトコードである。

つぎに，構築した学習空間を図5に示すそれぞれのニューラルネットワークに学習させる。DELTA_FLIGHTクラスを例として学習方法について述べる。Hierarchy moduleは，DELTA_FLIGHTクラスコードである0011を学習する。Attribute modulesについては，departure_airportを例に説明する。Key moduleのClass moduleは，表3に示した属性コードのうち $c_j r_{ji}$ である11100000を，Hierarchy moduleは $\bar{c}_j \bar{r}_{ji}$ である1010を学習する。Value moduleにおいては，Self moduleのClasscode moduleがAirportクラスコードの11を，Inheritance moduleのClasscode moduleがAirportの継承クラスコードである10を学習する。また，Self moduleのLocalcode moduleは表6に示す学習例を，Inheritance moduleのLocalcode moduleは表7に示す学習例を瞬時学習法¹⁵⁾を用いて学習する。

ここでは実装モデルとして，ニューロ・エージェン

表1 Areaクラスにおけるニューロ情報オブジェクトコード
Table 1 A neural information object code on Area class.

ニューロ情報	c_j	r_{ji}	\bar{c}_j	\bar{r}_{ji}
Los_Angeles	1 0	1 0	1 0	1 0
Washington_DC	1 0	0 1	1 0	0 1

表2 Airportクラスにおけるニューロ情報オブジェクトコード
Table 2 A neural information object code on Airport class.

ニューロ情報	c_j	r_{ji}	\bar{c}_j	\bar{r}_{ji}
Lax	1 1	1 0 0 0 0 0	1 0	1 0
Burback	1 1	0 1 0 0 0 0	1 0	1 0
Long_Beach	1 1	0 0 1 0 0 0	1 0	1 0
Dullas	1 1	0 0 0 1 0 0	1 0	0 1
Baltimore	1 1	0 0 0 0 1 0	1 0	0 1
National	1 1	0 0 0 0 0 1	1 0	0 1

表3 Areaクラスにおける属性コード

Table 3 A neural information attribute code on Area class.

属性	c_j	r_{ji}	\bar{c}_j	\bar{r}_{ji}
departure_area	1 0	1 0	1 0	1 0
arrival_area	1 0	0 1	1 0	0 1

表4 Airportクラスにおける属性コード

Table 4 A neural information attribute code on Airport class.

属性	c_j	r_{ji}	\bar{c}_j	\bar{r}_{ji}
departure_airport	1 1	1 0 0 0 0 0	1 0	1 0
arrival_airport	1 1	0 1 0 0 0 0	1 0	1 0
departure_station	1 1	0 0 1 0 0 0	1 0	1 0
arrival_station	1 1	0 0 0 1 0 0	1 0	0 1
departure_busstop	1 1	0 0 0 0 1 0	1 0	0 1
arrival_busstop	1 1	0 0 0 0 0 1	1 0	0 1

トモデル¹⁶⁾に本モデルの機能を追加したオブジェクト指向ニューロ・エージェンモデルを開発した。本モデルは，個々の階層型情報を特徴づける要素や推論のための手続き等をオブジェクトとしてカプセル化し，各ノードのメッセージのやりとりによって推論を行う並列オブジェクトモデルである。本モデルをSmalltalk-80を用いてSUN sparcl0およびMacintosh上に実装した。並列オブジェクトモデルにおいて，各ノードは推論に必要なパラメータおよび手続きを内部に保持し，推論の際にはメッセージに応じた処理をノード自身が実行し判断する。

以下では，Query_CC_JOURNEY (departure_area: Los_Angeles, arrival_area: Washington DC) の問合せを例として説明する。これはCC_JOURNEYクラスには存在しない。また，下位クラスにおいて属性が違っているので検索が煩雑となる。しかし，本システムにおいては，インデックス化された学習空間を学習した

表5 CC_FLIGHT クラスにおけるニューロ情報オブジェクトコード

Table 5 A neural information object code on CC_FLIGHT class.

ニューロ情報	c_j	r_{ji}	\bar{c}_j	\bar{r}_{ji}
CC_FLIGHT ₁	0 0 1	1 0	0 0 1	1 0
CC_FLIGHT ₂	0 0 1	0 1	0 0 1	0 1
DELTA_FLIGHT ₁	0 0 1 1	1 0 0 0	0 0 1	1 0
DELTA_FLIGHT ₂	0 0 1 1	0 1 0 0	0 0 1	1 0
DELTA_FLIGHT ₃	0 0 1 1	0 0 1 0	0 0 1	1 0
DELTA_FLIGHT ₄	0 0 1 1	0 0 0 1	0 0 1	0 1

表6 DELTA_FLIGHT クラスにおける自己属性学習空間の例 (出発空港)

Table 6 A learning example of departure-airport self attribute on DELTA_FLIGHT class.

departure-airport	Input units	Outputs units			
		#123	#312	#321	#567
Lax	1 0 0 0 0 0	1	1	0	0
Burback	0 1 0 0 0 0	0	0	1	0
National	0 0 0 0 0 1	0	0	0	1

表7 DELTA_FLIGHT クラスにおける継承属性学習空間の例 (出発空港)

Table 7 A learning example of departure-airport inheritance attribute on DELTA_FLIGHT class.

departure-airport	Input units	Outputs units			
		#123	#312	#321	#567
Los	1 0	1	1	1	0
DC	0 1	0	0	0	1

ニューラルネットワークにより同時並列推論される。すなわち、生成された問合せメッセージ

$$Q = (((1010\ 1010)(10\ 10\ 10\ 10)) \\ ((1001\ 1001)(10\ 01\ 10\ 01))) \quad (18)$$

が各クラスに送られる。たとえば、departure_area: Los_Angelos を意味するコード ((1010 1010) (10 10 10 10)) は、属性コード (1010 1010) が Key module に入力され、departure_area に関する属性を持つクラスの Attribute module が活性化され、その Value module に (10 10 10 10) が入力され関係するニューロオブジェクトが発火する。arrival_area も同様に推論される。この結果ニューロ情報オブジェクト DELTA_FLIGHT₁, 2, 3 が発火し、解として提示された。記号処理による推論の場合は、Los_Angelos の下位の概念である Airport クラスのインスタンスを検索し、問合せの内容を変更して再度推論を行う逐次処理となる。これと比較して、本システムは同時並列的推論が可能である。また、Query_DELTA_FLIGHT (departure.airport:

LONG.BEACH, arrival.airport: DULLAS) の問合せに対し、これに該当する情報は入力学習空間に存在しないが、DELTA_FLIGHT₂を検索した。このような場合、記号処理モデルにおいては、回答が得られない。しかし、本システムにおいては、構造を学習しているため、情報が不十分であっても近い情報を連想できる利点があることが分かった。

7. おわりに

本論文では、構造化および体系化された概念知識をニューロ情報として処理するための情報処理モデルとしてオブジェクト指向ニューラルネットワークモデルを提案した。オブジェクト指向データモデルとして概念知識をニューロ情報として処理することを可能にする適切なインデックス化法を導入した。また、オブジェクト指向モデルに基づく大規模で異質なニューラルネットワークの学習空間の構築法を提案した。オブジェクト指向モデルに基づきクラス階層組織の概念を導入した。クラス階層組織として構築される学習空間の各ノードには、同質のデータ構造を持つ学習例の集合を対応させ、それらのノードを組織化することにより異質で大規模なニューラルネットワークを構築法を提案した。ニューロ情報の組織化と推論モデルを、インデックスの操作手続きとして定式化し、連想データベースへ応用した。オブジェクト指向の汎化と集約化の概念に基づきそれぞれ異なる型の複数の学習空間の組織化法について、異質なニューラルネットワークを構築し対象世界を学習した。応用例として本モデルを連想データベースへ応用した。特に、ニューラルネットワークとオブジェクト指向モデルとの融合により、記号表現された意味情報 (概念階層) に基づく推論が可能になることを示した。

参考文献

- 1) Arbib, M.A.: *The Metaphorical Brain2-Neural Networks and Beyond*, John Wiley & Sons (1992). 金子隆芳 (訳): ニューラルネットワークと脳理論, サイエンス社 (1992).
- 2) Barnden, J.A. and Pollack, J.B.: *A High-Level connectionist Models*, Ablex Publishing (1991).
- 3) Barnden, J.A. and Srinnivas, K.: *Encoding Techniques for Complex Information Structures in Connectionist Systems*, *Connection Science*, Vol.3, No.3, pp.263-309 (1991).
- 4) Chu, W.W., Chen, Q. and Lee, R.C.: *Cooperative Query Answering via Type Abstraction Hierarchy*, *Cooperative Knowledge-Based Systems 1990*, Deen, S.M. (Ed.), pp.271-292, Springer-

- Verlag (1990).
- 5) Hinton, G.E.: Mapping Part-Whole Hierarchies into Connectionist Networks, *Artificial Intelligence*, Special Issue on Connectionist Symbol Processing, Vol.46, No.1-2, pp.47-75 (1990).
 - 6) Hinton, G.E.: Special Issue on Connectionist Symbol Processing, *Artificial Intelligence*, Vol.46, No.1-2 (1990).
 - 7) 石川真澄: コネクショニズムと学習, 認知科学の発展, Vol.4, No.4, pp.51-77 (1991).
 - 8) 石川真澄: モジュール構造のネットワーク学習, 人工知能学会論文誌, Vol.7, No.4, pp.567-574 (1992).
 - 9) Minsky, M.: *The Society of Mind*, Simon and Schuster, New York (1985). 安西祐一郎 (訳): 心の社会, 産業図書 (1991).
 - 10) 仁木和久: 自己組織型情報検索システム: SIR, 日本神経回路学会誌, Vol.1, No.1, pp.27-34 (1994).
 - 11) Parsaye, K., Chignell, M., Khoshafian, S. and Wong, H. (Eds.): *Intelligent Databases*, John Wiley & Sons (1989). 近谷英昭 (訳): 知的データベース, オーム社 (1992).
 - 12) Stanfill, C. and Waltz, D.: Toward Memory-Based Reasoning, *Comm. of the ACM*, Vol.29, No.16, pp.1213-1228 (1986).
 - 13) 所真理雄, 松岡 聡, 垂水浩幸 (編): オブジェクト指向コンピューティング, 岩波書店 (1993).
 - 14) Tourezky, D.S.: BoltzCONS: Dynamic Symbol Structures in a Connectionist Network, *Artificial Intelligence*, Special Issue on Connectionist Symbol Processing, Vol.46, No.1-2, pp.5-46 (1990).

- 15) 塚本義明, 生天目章: 多層ネットワークの瞬時学習法, 情報処理学会論文誌, Vol.34, No.9, pp.1882-1891 (1993).
- 16) 塚本義明, 生天目章: ニューラルネットワークの分散学習, 情報処理学会論文誌, Vol.35, No.12, pp.2664-2675 (1994).

(平成7年4月21日受付)

(平成8年5月10日採録)

塚本 義明 (正会員)



1963年生。1986年防衛大学校応用物理学卒業。1992年防衛大学校研究科(オペレーションズリサーチ専攻)修了。現在、防衛大学校情報工学教室研究員、日本神経回路網学会、人工知能学会、日本ソフトウェア科学会各会員。

生天目 章 (正会員)



1950年10月4日生。1973年防衛大学校卒業(応用物理学専攻)。1977年および1979年スタンフォード大学大学院修士および博士課程修了(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、意志決定工学等の研究に従事。人工知能学会、ソフトウェア科学会、神経回路学会、AAAI, ACM, IEEE 学会各会員。