

PDAI & CDに基づく意味の学習および文脈依存の多義性解消 —神経回路網と論理記号処理の統合による連想推論—

角田 達彦、白石 知之、田中 英彦

{tsunoda,tshira,tanaka}@mtl.t.u-tokyo.ac.jp

東京大学工学部

〒113 東京都文京区本郷7-3-1 東京大学工学部電気工学科 田中英彦研究室
03-3812-2111(7413)

*日本学術振興会特別研究員

あらまし

本論文では、人間の推論の基本的部分として、神経回路連想網と論理記号処理による制御および検証を目的としたPDAI & CDアーキテクチャを提案する。連想部では外界の頻度情報から学習された概念間の関係をもとに状況依存の自由連想を行なう。論理記号部では明示的に与えられた知識をもとに推論した結果に矛盾が生じないかを検証し、連想部にフィードバックをかけることにより最尤解が出力される。その実装システムとしてWAVEを紹介するとともに、自然言語の語の多義性を外界から獲得した情報により文脈に依存して解消する例、また文字認識システムに適用した例を示す。データベースシステムとしてのWAVEの位置付けについても考察を行なう。

和文キーワード 神経回路網、論理記号処理、連想、学習、文脈依存性、多義性解消、意味

Learning and Context Dependent Ambiguity Resolution of meanings of words by PDAI&CD Associative Inference by Integration of Neural Networks and Logical Processings

Tatsuhiko TSUNODA *, Tomoyuki SHIRAISHI, Hidehiko TANAKA
Tanaka Hidehiko Laboratory, Department of Electrical Engineering,
Faculty of Engineering, University of Tokyo
7-3-1 Hongo, Bunkyo-ku, Tokyo 113, Japan
{tsunoda,tshira,tanaka}@mtl.t.u-tokyo.ac.jp

*Supported by the Fellowships of the Japan Society for the Promotion of Science for Japanese Junior Scientists

Abstract

In this paper we propose PDAI&CD architecture aimed to construct natural inference systems. The kernel of it consists of mutually associative neural network processing numerical patterns and logical part processing symbols. The associative part evokes context-dependent free-association of concepts based on the relations of concepts acquired from the outer world changing dynamically. In the logical part, thus obtained results are checked, and emerging contradictions cause feedback to the associative network finding the optimum solutions finally. WAVE, the concrete implemented system, is introduced, and we show the application to the ambiguity resolution problem of natural language understanding. We also illustrate the application to the character recognition system and examine the role of WAVE as a database system.

英文 key words neural network, logical processing, association, learning, context dependency, ambiguity resolution, semantics

1 はじめに

従来計算機が取り扱ってきた問題や言語は、曖昧性がないように設定され、知識も変更が加えられないものが多かった。しかし近年、表面的に知識を格納しておき、取り出すだけにとどまらず、知識を動的に学習することによって獲得すること、および意味や状況依存性まで踏み込んだレベルの解析を行なうことが求められるようになった。

具体例として自然言語処理・理解、機械翻訳などがあり、意味解析や文脈処理によって構造解析などにフィードバックをかけたリ、意味を理解することの必要性があげられてきている。またデータベースシステムにおいても、これまでは基本的操作を人間側が処理に応じて組み合わせ、条件に応じて書き込み/読みだしを行なうものであったが、知識を構造化して格納する人件費の問題、不完全な情報をもとにした処理が困難なこと、そして状況に依存して適切な解答が得られるシステムの要望が論点になっていくと予測する。

この論文では、このような状況に依存した推論を行なうための新たな枠組となるアーキテクチャと学習可能な意味表現を提案する。知識は視覚情報などの五感によって動的に与えられて学習されていくものと、明示的構造をもつルールに分けられる。前者は神経回路網によって付加的に学習され、後者は知識ベースにルールの形で蓄えられる。データが入力されるとまず、神経回路網上で関連するイメージを超並列に連想し、最尤解を超並列に選択する(PDAI: Paralle Distributed Associative Inference)。そして候補としてあがった解答を、知識ベースのルールと矛盾しないか検証を行なう(CD: Contradiction Detection)。この具体的な実装システムとしてWAVE (Winner Associative Voting Engine)[1, 2, 3]、その自然言語への適用した結果[4]、そして連想補完文字認識システムを紹介する。またWAVEのデータベースシステムとしての位置付けについて説明を行なう。

2 意味の外延的表現、文脈依存性および学習

まず、例題として次のような文を考えてみる[5]。

- (a) John shot some bucks.
- (b) The astronomer married the star.
- (c) The sailor ate a submarine.

文(a)には大変な状況依存性がある。shoot や buck にはそれぞれ数十通りの意味がある。従って文全体の解釈としては、その組み合わせの何百通りの訳し方が出てきてしまう。しかし実際に意味の通る訳としては、その中の数種類に過ぎない。さらに適切な文脈のもとでは曖昧性がほぼ解消される。「森の中」の文脈では、「John は牡鹿を何頭か撃った」、そして「カジノでギャンブルをしている」場合には「John は何ドルかすった」という解釈になる。このように、文脈と単語間の意味の連想により、他の単語の意味の引き込みが現れている。

文(b)、(c)にはまた違う問題が発生している。star や submarine という単語は日常的には「星」や「潜水艦」という意味があり、また文中の astronomer や sailor という単語の意味からも引き込まれて連想し、このような通常の意味に落ち着きがちである。だが人間の場合には、得られた解答を吟味し、より適切な意味を求めることができる[5]。文(b)の star という語に対して、最初に連想される意味「星」を文の中で使えるか否かを検証し、次の意味候補「映画スター」を採用する。このようにして(b)の意味は「その天文学者は映画スターと結婚した」となる。同様に、(c)も「潜水艦」ではなく、「その水夫はサンドイッチを食べた」となる。これらの文は、文脈がなくても常識的な判断で正しい解釈をすることが可能である。

これらの例を人間の思考の面から解析し、神経回路網の上にその認知科学的モデルを実装して実験を行なった Waltz と Pollack の研究がある[5]。入力レベル、構文レベル、意味レベル、文脈レベルを一つのネットワークの上に構築し、ニューロンの発火と伝搬によって最終的に語の多義性が解消されている。興奮性結合と抑制性結合の二種類の結合の作用で葛藤が生じ、解決されるプロセスは人間の思考に似ているという考察が述べられている。しかしこのモデルには問題点も多い。

- 二種類の結合は人間の手で恣意的に張られ、重み値を得る学習方法が全く書かれていない

- 単語のマイクロフィーチャの定義が曖昧
- 文脈部が区別され、予め定義された単語のみが文脈となりうる
- 人間の思考は様々なレベルや知識による干渉や中断・再開が入るのだが、このモデルではインタラクションに対処する術がない

一段の推論で最初から正解を出すような知識にしておくことは、限られた文の中では有効であるが、汎化能力の面で脆弱性が生じてしまう。変化する実世界から動的に学習を行なうには、一般的事象から連合対記憶を利用して学習した知識を利用して推論し、陽に教えられた例外的関係をルール形で持ち、連想部にフィードバックをかける形態の方が、頑健性が高い。

意味の表現方法は、上記のように語の連想をもって理解すると定義するため、語の意味をトップダウンに定義する内包的表現ではなく、実世界に現れた他の語との関係によって定義する外延的表現を用いる。

3 PDAI & CDアーキテクチャ

PDAI & CDは、人間の推論は連想のステップを積み重ねて成り立つという仮説に基づいている。その過程のもっとも基本的ステップは、センサによって獲得されるイメージの連想による。外界からのリアルタイムのフィードバックは動的に変化する世界の構造を反映したものになっており、その情報から自己組織化を行なう。その特徴抽出機構はネオコグニトロン[6]のように階層的構造をとる(図1)。最下層では視覚情報の修復から、最上層では言葉のような抽象的概念の相互想起まで、その階層内、階層間で機能の異なる連想が起こる。

最下層の付近では、学習は外界の特徴を反映した長期的自己組織化が行なわれるが、最上層の付近では、抽象的概念を相互自由連想する枠組があり、より柔軟で追加の可能な形になっていると思われる。階層間で最も矛盾が小さくなるように選択が起こり、ここでも高密度な連想が働いている。

各層および層間は基本的に同じ構造をとっており、下層からの連想情報をもとに層内で自由連想し、上層からのフィードバックと層内の矛盾を解消し、下層にフィードバックし直す。リアルタイ




図1: PDAI & CDアーキテクチャ

ムで高速な処理が必要な場合には、上層には情報は渡されず、上層での検証は行なわれない。

このPDAI & CDアーキテクチャのもと、特に最上層の概念レベルの自由な相互連想および外界からの事例の頻度情報を利用して学習する神経回路網上の連想システム、そしてルールデータベースに知識として格納された論理的情報を基に検証を行なう部分を統合したシステムを実装し、実験を行なったのでその結果を以下に示す。

4 実装システムWAVE

WAVE [1, 2, 3] は自由連想を行なう部分、積和演算を行なう部分、選択を行なう部分より成る神経回路網、そして明示的構造をもつ知識により検証を行なう論理記号処理の部分の二つに分けられている。ここでは特に神経回路網上の自由連想から選択まで、そして学習方法を説明する。

4.1 連想

連想は基本的には学習された概念の1対1関係の想起に基づく。ここでは新しく、単語で表された概念を複数入力して神経回路網内で想起し、それに対応する概念を再び単語にて出力することを目的とし、獲得した知識に基づき、状況依存の確信度順自動選択を可能とする連想推論機構の実現に向けて1対多の連想処理を拡張する(図2)。各

概念は対応して記憶されるニューロン ($r \in R$) と、その活性値 $U(R)$ で表現される。

$$R = \{i | \langle i | A | k \rangle \langle k | s \rangle \neq 0, i, \forall k \in \sigma\}. \quad (1)$$

ここで σ は神経回路網の空間中の全ニューロンの集合を示し、 k は伝搬時の活性値の送り手である。連想演算子 A により、次の状態に遷移した後での各ノードの活性値は次の様に計算される。

$$\langle r | s' \rangle = \sum_{\forall k \in \sigma} \langle r | A | k \rangle \langle k | s \rangle. \quad (2)$$

$$|s \rangle = |s \rangle_{input} + |s \rangle_{context}. \quad (3)$$

この均質的ネットワークでは、複雑な構造は規定していないので、通常の神経回路網や超並列計算機に容易に実装可能である。

4.2 概念の外延的定義と学習

概念は内包的定義ではなく、それまでに呈示された世界の中の他の概念との関係によって定義する、限定された外延的定義によって表現する。この表現方法によれば概念の特徴を表す基底を決めることはせず、新しい概念属性を適宜学習する能力を持つので、部分による知識学習から全体判断への枠組を構成することが可能である。

$$\langle r | A | k \rangle = \frac{\langle r | R_w | k \rangle}{\sum_p \langle p | R_w | k \rangle} \quad (4)$$


ただし R_w は実世界、 r, k は概念ノードで、連合対の頻度情報により学習を行なう。このため、概念間の関係を動的に付加することができ、外世界からの新しい概念にも柔軟に適用可能である。その表現を2次元に展開した様子は、後の自然言語へ適用した例の中で表す (図5)。

4.3 最適連想の選択

この機構の目的は優先度付きの入力された複数の単語の組から制約を受けて連想される単語を、確信度順に自動的に選択することである。上記のごとく、想起される概念イメージ全体は入力された言葉に対して意識下で想起される複数の概念の混合状態になっている。

随時付加的学習を可能とするために、1) 競合概念間に学習時に抑制性結合を張ることはしない、2)

Symbol Constraining Concepts & Symbol Recalled Concepts



Associated Concepts

図 2: 最適連想概念の選択

想起時に最適概念を出力する、という設計を行なった。これにより、競合する概念を恣意的に選び出して抑制性結合を手で張ることをせずに済み、想起時に意識の集中を行なって最適概念を選び出すことが可能である (図2)。

最適概念 (場合によっては複数可能) によって活性化されるノードにより想起される概念全体は次のようになる。

$$Q = \{i | \langle i | s' \rangle \geq \langle j | s' \rangle, i, \forall j \in \sigma\}. \quad (5)$$

この様な最適解選択機構の具体的実装方法として、神経回路網を使用する場合と、超並列計算機を使用する場合の2種類が考えられる。どちらの方法も超並列の協調分散処理によって選択し、全体的コントローラが不要であり、拡張性のある方法を提供することができる。連想などの応用例では、ほぼ定数オーダーで処理することができる [2, 3, 1]。

5 自然言語文の語の多義性解消

ここでは、WAVEの自然言語処理における意味レベルの解析への応用を目的 [4] とするため、いくつかの限定を行なっている。まず、単語の多義性を状況に依存して解消し意味を求めることを、この場合の自然言語理解と位置づける。次に、形態素解析、構文解析、検証は基本的に記号処理部により、神経回路網の一回の意味解析ごとにインタラクションを行なう。具体的にWAVEとのインタフェースとして以下の部分の付加を行なった。

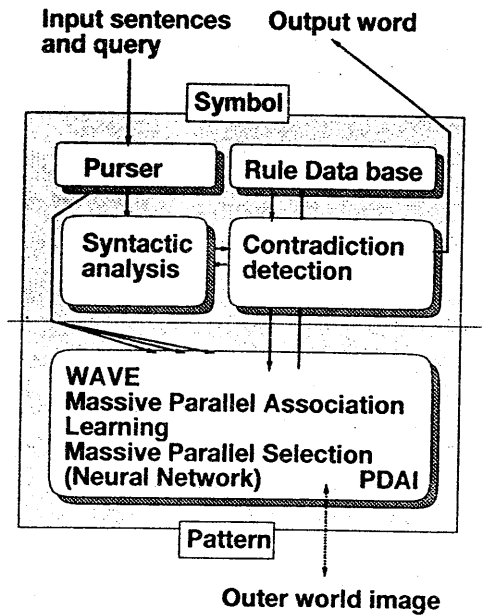


図 3: 自然言語理解システムの概要

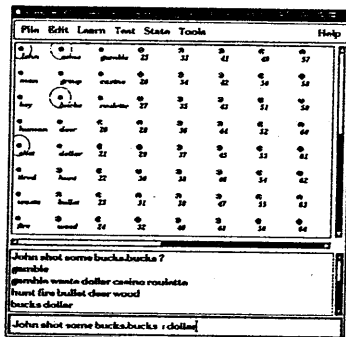


図 4: X-Window 上のシミュレーション

- 入出力ウィンドウ (X-Window 上、図 4 の最下段。その上には履歴が表示される。)
- 文の末尾の “?” によって質問文を区別
- 単語のノードへの自動割当て、リンク更新
- 質問文の末尾の “?” を解で置き換える
- 質問文中の単語は抑制する
- 記号処理部分で検証し、フィードバック

5.1 John shot some bucks.

例題としてまず 'John shot some bucks.' を考える。人間の答えとしては、「狩猟」という文脈では「John は何匹かの牡鹿を撃った。」となり、「ギャンブル」という文脈では「John は何ドルか損した。」

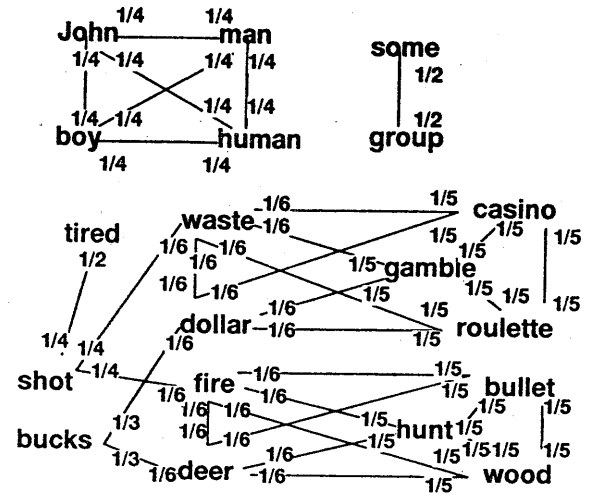


図 5: 文 (1) ~ (9) の外延的表現

という意味になる。'shot' や 'bucks' という単語の多義性のため数百通りにもなる組み合わせのなかから一意に解を得るのは非常に難しく、ルールで全情報を得るには限界があるという、本質的問題である。

WAVE システムは最初は何の知識も持たない。入出力ウィンドウから以下の文章が直に入力されていく。

- (1) John man boy human
- (2) shot tire
- (3) shot waste
- (4) shot fire
- (5) some group
- (6) bucks deer
- (7) bucks dollar
- (8) hunt fire bullet deer wood
- (9) gamble waste dollar casino roulette

ここまでで文を理解する世界像が構成される。例えば (1) が入力されると、含まれている 4 つの単語がノードに自動割り当てされ、リンクが張られ、重みが計算されていく。以降の知識が入力されると、新しいノードが割り当てられけたり、リンクの一部が強化されることがあるので、一般には重みは等しくなく、また非対称である。文 (1) ~ (9) まで入力した段階で、作成された概念マップと相互の結合値は図 5 のようになる。

次に、全く同様に、次の文 (単語) を入力する。

- (10) gamble

システムは単に gamble に対応するノードの活性

値を上げ、関係する概念を想起するのみであるが、人間にとっては、状況の呈示という意味を持つ。gamble という単語を使ったが、casino など、関係する任意の単語を使用できる。文脈専用の単語を用意しているのではなく、エピソード記憶による連想をもって文脈としている。

ここで次の文を入力すると、システムは質問文として解釈を行ない、各単語の活性値を上げ、概念を想起する。

(11) John shot some bucks.bucks ?

そして文の末尾の '?' を '<最適連想解>' で置き換えたものが出力される。

(12) John shot some bucks.bucks:dollar

この答えは確かに、'gamble' という状況では 'bucks' という単語は 'dollar' という意味であることを表す。各ノードの活性値は以下ようになる。

node	value	node	value	node	value
John	0.025	man	0.025	boy	0.025
human	0.025	shot	0.027	tired	0.025
waste	0.034	fire	0.025	some	0.050
group	0.050	bucks	0.068	deer	0.067
dollar	0.076	hunt	0.000	bullet	0.000
wood	0.000	gamble	0.009	casino	0.009
roulette	0.009				

質問文の最後の 'bucks' と 'gamble'、'shot' などの引き込みにより 'dollar' という単語の活性値が最も高くなるのがわかる。また、上の手順と同様にして、それぞれの文脈を想起させる単語 (例えば casino など、任意) を与えた後で、それぞれの単語の意味を呈示するように要求した結果、表のように正しい結果を得ることに成功した。

context	resolution	
		shot
hunting	fired	deers
gambling	wasted	dollars

5.2 The astronomer married the star.

この例題に対して人間は、「天文学者は星と結婚した。」と言いそうになって「いや、映画スターだ。」と訂正するのが大抵である。文脈情報を与

えずにシステムにこの問題を解かせると、やはり「星」の方を選んでしまう。それは 'star' が「星」であるという頻度が高いことに主に起因する。そして「天文学者」がさらに「星」を連想させてしまうのだが、次のようなルールによる知識が検証部で呼び出され、連想部にフィードバックをかけることによって次の候補 'movie_star' が得られた。

contradiction(S):-analyze(S, [], N1, V, N2),
V=married, not(human(N1)).

contradiction(S):-analyze(S, [], N1, V, N2),
V=married, not(human(N2)).

S は入力する文をリストにしたものである。analyze は構文解析を行ない、主語と動詞、目的語が求められる。ただし、簡単のために SVO の文型のみを対象にしている。条件を厳しくし、「結婚できるのは人間だけ。」という知識が表現されており、この条件を満たさないときは contradiction が yes になる。そしてそのときにのみ、連想部にフィードバックがかかる。この思考過程は人間の推論によく似たものになっている。

with feedback	res. of star
before	celestial_body
after	movie_star

このように、PDAI & CDアーキテクチャは、エピソード記憶によって獲得される知識による自由な連想と、ルールとして明示的に与えられた知識による制約を組み合わせ、従来の推論に比べてより自然な推論を行なうことができる。

6 連想補完文字認識

もう一つの応用例として、文字認識に PDAI & CDアーキテクチャを適用した例を示す。目的は、文字全体が単語の中で欠損してしまった場合や、有名な 'THE CAT' の例 [7](図6) などで、文字レベルでは 'H' が 'A' が区別がつかないとき、文脈から判断して多義性を解消しなくてはならない場合に、全体として矛盾の無い解答を得ることである。一文字認識の部分は ART [8] と呼ばれる神経回路網を使用し、単語レベルの制約部は独自のスペルチェックを開発し、論理記号で実装を行なった。ARTの特長は、パターン認識のカテゴリを

TAE CAT

図 6: 文字の多義性の例: THE CAT




図 7: 一文字のみにノイズを加えた場合

任意に増やせるため、学習は一回のみで済み、追加をすることができる点である。このため、新しい文字やフォントにも自由に対応することができる。学習部は階層的特徴抽出を行なうため、文字ごとに人間がルールを作る必要はない。また制約のフィードバックを受け、次候補を出したり、学習制御が出来る点は、他の神経回路網にはない特長であり、必要不可欠である。単語レベルの論理制約部は逆に、知識としての単語のデータベースがあるので、人間が新しい単語を容易に登録できる利点がある。一文字ごとの確信度を集計し、単語レベルで最も矛盾の少ない候補を最終解として出力するとともに、文字の学習を行なう。評価方法としては、文字ごとの確信度をパラメータとして認識率を求めることを目的とし、模擬的に 1) 単語中の一文字にノイズを加える、2) 単語全体の文字に均一にノイズを加える、3) 文字ごとに異なる割合にノイズを加えるなどの実験を行なった。そのうち前 2 例のみを示す(図 7、8)。このように、ファクシミリなどでよく起こるような文字の汚れ、薄れ、特に一文字欠損などで単語レベルで連想補完をする効果が現れている。それは同時に手書き文字認識などでも有効であることを示す。

このように、PDAI & CD の枠組に沿って神経回路網と記号処理を統合すると、知識の種類に応じて学習を行なえるとともに、認識率の向上を




図 8: 単語全体に均一にノイズを加えた場合

期待できることがわかる。文字認識の課題としては、上記のような自然言語などの応用例の意味や文脈などのより高次の連想から制約を与え、さらに実用性を高めることを目標とする。

7 DBMSとしてのWAVE

WAVEの核となる超並列連想部の基本的機能は、以下の通りである。

1. 概念間相互作用による超並列連想
2. 逐次学習可能な、概念の外延的分散表現
3. 最尤解の高速選択

その形態はリレーショナル・データベース(RDB)に非常に似ている。概念と関係子を明示的に区別せず、積集合を基本的演算に使用する。ただし、WAVEの積集合は拘束条件ではなく、最尤のものを求めるためである。従って、質問としての単語群に間違っただけのものが入っていても、フィードバック・ループによって目的の答えが得られる可能性が大きい。また頻度情報をもとにした連続値によって重みを計算するため、概念の距離関係が答の非決定性を解消し、最尤解を得ることができる。連合対記憶の頻度情報をベースとして学習を行なうので、例えば画像イメージのように関係を陽に構造化して記述するとコストがかかり過ぎるような場合に、より自然な知識の獲得を行なうことができる。概念ごとにプロセッサが対応し、超並列に選択を行なえるアルゴリズムをとっている。

このように、WAVEは従来のRDBに柔軟性を持たせ、また構造を明示的にもたない形でのデー

タからの学習という知識獲得の自動化を行なったものとも位置付けられる。さらに制約をルールの形で与えることにより、再考してより誤りの少ない解答をユーザに提供するシステムである。

8 おわりに

以上のように、実世界の中での推論は非常に曖昧性のある概念をとり扱うことが多く、文脈依存の多義性解消が必要である。また知識は動的に増えていくので、最初から知識量を限定しておくことはできない。従って環境の中で必要と思われる知識を獲得し、推論に役立てることが不可欠である。PDAI & CDはこのような低次レベルの事象からの学習による知識獲得と、より抽象レベルからのフィードバックやコントロールを基に推論を行なうアーキテクチャである。それを神経回路網による学習および連想、そして論理記号処理による矛盾検出などの検証、制御を組み合わせる実装したシステムがWAVEである。具体的な例題として自然言語の語の多義性を、文脈に応じて解消できることを示した。この手法は自然言語に限らず、一般的な推論にも有効であると考えられる。また現在では限られた操作のみ許されているデータベースシステムに対しても、構造を明示的に持たない知識を動的に変化する外界から獲得し、不完全な情報を基にした柔軟な検索を可能にする方法を提供することになる。自然言語の問題に対しても、データベースシステムの場合でも、並列性のある実装をしないと、処理時間が爆発してしまう。このWAVEシステムでは超並列に連想し、高速選択をするステップを繰り返すため、本質的な超並列性と、制御の逐次性を兼備する。

同様に、文字認識システムに対してこのアーキテクチャを適用し、実験を行なった結果、知識や処理を階層化し、層内連想、層間連想を有効に利用することによって、より頑健性の高い推論を高速に行なえることが示された。

現在各種の推論方式が提案されているが、ルール指向の場合には知識獲得の方法や制約の取り扱いに問題点が生じる。逆に数値指向の場合には、適切な選択方法や距離の計算方法の一元化が難しくなる。ここでは、神経回路網による学習・推論や、

MBR、各種統計手法の数値に基づく推論・解析方法と、ルールに基づく明示的表現をもつ知識を利用することにより、信頼性を高めかつ、より柔軟で高速な処理が可能であることを提唱した。視覚情報などの五感に基づくデータを利用した学習を行ない、またより一般的な推論に適用・実験を行なうとともに、動的な文脈に対処できる枠組を構築することを今後の課題とする。

参考文献

- [1] T.Tsunoda and H.Tanaka. Winner associative voting engine (wave). In *Proceedings of IJCNN, Beijing vol.3*, pp. 589-594, 11 1992.
- [2] 角田達彦, 田中英彦. 神経回路網に基づく超並列連想システムWAVE. 情報処理学会第45回全国大会, Vol. 7E-2, pp. 47-48, 1992.
- [3] 角田達彦, 田中英彦. 汎用並列連想システムWAVE. 電子情報通信学会技術研究報告 AI92-39, Vol. 92, No. 184, pp. 17-26, 1992.
- [4] 角田達彦, 田中英彦. 神経回路連想システムWAVEの自然言語理解への適用. 情報処理学会第46回全国大会, Vol. 3, pp. 191-192, 1993.
- [5] D.L.Waltz and J.B.Pollack. Massively parallel parsing: A strongly interactive model of natural language interpretation. *COGNITIVE SCIENCE*, Vol. 9, pp. 51-74, 1985.
- [6] S.Miyake K.Fukushima and T.Ito. Neocognitron: a neural network model for a mechanism of visual pattern recognition. *IEEE trnas.*, Vol. SMC-13, pp. 826-834, 1983.
- [7] D.E.Rumelhart and J.L.McClelland. *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*. MIT Press, 1986.
- [8] G.A.Carpenter and S.Grossberg. The art of adaptive pattern recognition by a self-organizing neural network. *IEEE Computer*, Vol. 21, No. 3, pp. 77-88, 3 1988.