

PDPモデルによる診断エキスパートシステム

斎藤 和巳 中野 良平

(NTT 電気通信研究所)

本稿では、PDPモデル(Parallel Distributed Processing)の知識処理への適用性を明らかにすることを目的とし、学習アルゴリズムとしての有望性が広く認められたバックプロパゲーションを探り上げ、以下の検討を行った。まず、PDPモデルの診断(判定)能力を評価するため、PDPモデルによる頭痛の診断システムを作成した。同システムに学習させ、未知の患者に対する診断結果に基づき、診断システムの能力、及びその可能性について考察を行った。次に、PDPモデルが学習した内容が記号表現ではどのような内容に対応するか調べるため、医師から抽出した知識と診断システムが獲得した知識を比較し、さらに、診断システムからのルールの抽出法について検討し、抽出したルールの評価を行った。

Medical Diagnosis Expert System Based on PDP Model

Kazumi SAITO Ryohhei NAKANO

NTT Electrical Communications Laboratories
1-2356, Take, Yokosuka-si, Kanagawa-ken, 238-03 Japan

We aim to clarify the applicability of PDP models(Parallel Distributed Processing) to knowledge processing. A learning algorithm called back propagation is selected, since the algorithm seems to be promising due to its generality and power.

In this paper, the following are presented. First, diagnosis (discrimination) capability of PDP model is evaluated by using a prototype of medical diagnosis expert system; after learning from hundreds of patients, the prototype system shows almost equivalent diagnosis capability to that of a symbolic expert system. Then, we try to represent what PDP model learns in symbolic forms: the knowledge extracted from doctors is compared with that considered to be acquired by the PDP diagnosis system, a rule extraction method is originally proposed, and extracted rules are evaluated.

1. はじめに

知識処理技術の発展にとって、学習や知識獲得は重要な研究項目の一つであり、多くの研究や定式化が進められている[1]。現在の知識処理システムやそこで扱う学習の殆どの知識表現法は記号表現に基づいたものであり、学習手続きはその表現法に基づいた記号処理となる。一方、本稿で取り上げた PDP モデル (Parallel Distributed Processing) の表現法は知識をネットワーク上の複数のユニットの状態とそれらの結合の強さで表現し、学習手続きはその結合の強さを変えるアルゴリズムとなる[2]。即ち、現在の知識処理システムを論理レベルの知識表現法と学習手続きであると考えれば、PDP モデルは物理レベルの知識表現法と学習手続きであると考えられる。

現在、PDP モデルは主に音声や画像の認識問題等に応用されつつあり、その成果も始めている。また、知識処理への応用例としては Hinton らの 3 項関係を学習させた例が有名である[3]。PDP モデルの知識処理への適用法には、次の 2 つのアプローチが考えられる。第 1 のアプローチは、PDP モデルが具体的な入出力パターンから知識を獲得していることを利用し、エキスパートシステム開発で最大のボトルネックと言われる知識獲得の自動化への道を開くことである。そのためには、まず、知識表現レベルのギャップを克服しなければならない。第 2 のアプローチは、PDP モデルにより診断問題等のエキスパートシステムを作成することである。その利点として、知識の獲得を自動化するだけでなく、エキスパートがルール等として明瞭に表現できない知識を PDP モデルでは利用できるのではないかと考えられるからである。勿論、PDP モデルの能力等は未知の部分が多いので、今後多くの研究が必要とされる。

本稿では、PDP モデルの中でも NETtalk [4] を始めとするシステムで使われ、その有望性が広く認められた学習アルゴリズムであるバックプロパゲーションを取り上げた。バックプロパゲーションとは多層ネットワーク (multi-layer network) と呼ばれるネットワークにおいて、実際の出力と要求する出力の差を小さくするように、ネットワーク中の結合の重みを繰り返し修正する手続きである。結合の重みを修正した結果、ネットワーク中に問題領域の重要な特徴や不变量が現れてくることが、いくつかの具体例により示されている。

本稿は PDP モデルの知識処理への適用性を明らかにすることを目的として、以下の検討を行った。まず、PDP モデルの診断（判定）能力を評価するため、知識処理研究部で研究開発を進めている医療診断支援システム*1 [5] のデータを利用し、PDP モデルによる頭痛の診断システム（以降、PDP 診断システムと呼ぶ）を作成した。同システムに学習させ、未知の患者に対する診断結果に基づき、PDP 診断システムの能力、及びその可能性について考察を行った。次に、PDP モデルが学習した内容が記号表現ではどのような内容に対応するか調べるために、医師から抽出した関係パラメータ*2 と PDP 診断システムが獲得した関係パラメータを比較し、さらに、PDP 診断システムからのルールの抽出法について検討し、抽出したルールの評価を行った。

*1 医療診断支援システムは専門家だけでなく、非専門家ないし一般の人々を対象にした、訴え（自覚症状）だけで診断を行う問診型である。

*2 関係パラメータとは症状と病名の関係の強さを表わすパラメータ RF (relation factor) のことであり、医療診断支援システムでは RF を基にルールを用いて診断結果を出している。

2. 診断性能評価

2. 1 PDP 診断システムの構成

本稿で作成した PDP 診断システムは、頭痛における症状をその病名に対応させるものである。その構成は 3 層のネットワークで、入力ユニットには患者の自覚症状から選ばせる症状の選択肢、出力ユニットには病名をそれぞれ対応させた（図 1）。例えば、図 1 の入力ユニットのグループ 1 は頭痛の部位に関する質問であり、グループ 1 の各ユニットは部位に関する質問の選択肢に対応する。次に、ユニット間の結合に関しては、全ての入力ユニットは全ての隠れユニット (hidden unit) と結合させ、全ての隠れユニットも全ての出力ユニットと結合させ

た。また、患者データは医療診断支援システムの評価のために取られたものを利用した。PDP診断システムの作成に当たり、以下の工夫をした。

(1) 病名の絞りこみ

P D P 診断システムは患者データを基に症状と病名の対応関係を生成するため、患者数の少ない病名に対しては診断することが困難である。そこで、3名

以上の患者のいる病名22個とそれ以外の合計23個を出力ユニットに割り当てる。

(2) 患者データの解釈

医療診断支援システムでは、以前の質問項目での回答から、あるルールに従い次の質問項目を決定するので、患者に提示されない質問項目が存在する。即ち、同システムでは各質問項目の選択肢は、患者が“選んだ”、“選ばなかった”以外に“質問しなかった”を加えた合計3値から成る。本システムでは“選ばなかった”と“質問しなかった”を区別しなかった。その理由は、両者はかなり近い意味を持ち（基本的に、質問しないのは患者が全ての選択肢を否定する質問項目であると判断されたためである）、さらに、2値で扱った方が入力ユニットにオンとオフの自然な対応付けができるからである。勿論、バックプロパゲーションの入力値は連続値を許容するので、3値を与えることは十分可能であるが、それはPDP診断システムの診断能力を向上させるチューニングに対応すると考え省略した。

2. 2 学習

学習データとして、300人分の患者データを使い、全体の誤差が殆ど変化しなくなるまで学習させた。そのとき、各パターンの学習回数は200回であった。PDP診断システムの出力ユニットの活性化値が0.75以上の場合はその病名の可能性を肯定し、0.25以下の場合はその病名の可能性を否定したと解釈して、学習に利用したデータを100%正確に学習した。

2. 3 未知の患者に対する診断

学習を終えたPDP診断システムに未知の94人の患者データを診断させた。一般に、一人の患者の実際の病名は一つであるとは限らず、PDP診断システムによる診断結果も一般に複数現れる。また、未知の患者に対するPDP診断システムの出力の解釈として、出力ユニット

の出力値に対して閾値(threshold)を設け、閾値を超えた場合、その出力ユニットに対応する病名を診断結果とした。一般に、閾値を大きく設定すれば誤った病名を出力をする割合は低くなるが、正しい病名を出力する割合も低くなる。逆に、閾値を小さく設定すれば正しい病名を出力する割合は高くなるが、誤った病名を出力する割合も高くなる。そこで、診断結果の評価尺度として、自由語検索等で利用される的中率(precision)と網羅率(recall)を用いた[6]。図2(a)に的中率と網羅率の概略を示す。自由語検索と同様、診断においても的中率と網羅率を共に向上させることが望まれる。図2(b)は、患者一人当たりに対する実際の正診とP D P診断システムによる診断結果を示す。この時、閾値は0.25に設定した。それは、その病名に対する可能性を否定していないものは診断結果とすべきであると考えたためである。

異なる評価尺度として、患者の複数の病名から少なくとも1つの病名を診断できたとき、その患者に対して正答できたとする正答率を用いると、本システムの正答率は67%となる。一

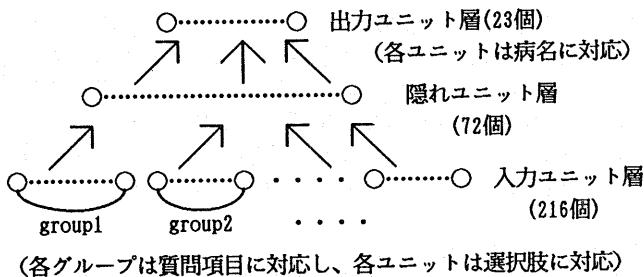


図1 PDP診断システムの構成

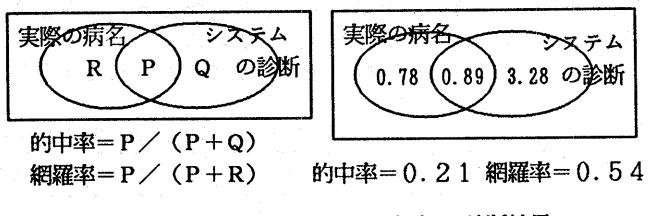


図2 (a) 的中率と網羅率 (b) 診断結果

方、この評価による医療診断支援システムの正答率は70数%と言われる。ここで、問診のみによる診断であることも考慮すれば、本システムの正答率は医療診断支援システムの正答率に近く、本システムはかなりの診断能力を有すると考えられる。但し、医療診断支援システムと比較すると、本システムは各患者に対してより多くの誤った病名を出力している。

本システムに対しさらに深く病名別、ネットワークの構造の変化、学習パターン数の変化による診断能力の変化を考察した。以下にそれらの結果を示す

2. 4 病名別の診断結果

本システムの病名別の診断結果を、実際にその病気でありながら病気でないと誤答した割合を α -error、逆に、病気でないのに病気であると誤答した割合を β -errorとして評価した(図3)。また、各病名に対して診断するための本来の決定境界が症状空間に存在すると仮定すれば、システムが形成した決定境界は、 α -errorが大きいならば拡張を必要とし、逆に β -errorが大きいならば縮小を必要とする傾向にあると考えられる。

診断結果の概略は、23種の病名のうち3種の病名は試験データ中に1人も患者が存在せず、7種の病名は試験データ中に数名の患者が存在したにも拘わらず、1つも病名を診断できなかった(α -error = 1)。これらの病名はいずれも学習パターン中の患者数が10名程度以下であり、本来の決定境界と比較して、決定境界がほとんど形成できていないと考えられる。そこで、学習データ中に20名以上の患者がいる病名の診断結果、及び全ての病名の平均値を比較してみた(表1)。但し、出力解釈の閾値は0.25に設定した。

表1より、平均的な病名の診断能力は β -errorに比較して α -errorがかなり大きく、全体でも各病名の決定境界の拡張が必要であり、そのためにはさらに学習データ数を増やすことが必要であると考えられる。次に、高い診断能力が得られたと考えられる病名はNo.12(頸性頭痛)及びNo.20(頭部打撲)であり、これらの病名は、本来、比較的狭い決定境界を持っているのではないかと考えられる。また、No.10(筋収縮性頭痛)は α -errorに比較して β -errorが大きい。その理由として、学習データの121名中この病名だけである患者は9名であり、残りは他の病名を1つ以上含んでいる。即ち、システムが他の病名が持つ症状をこの病名の症状として決定境界を形成してしまったと考えられる。

実際に患者は病気で		
システム の判断	ある	ない
病気で ない	$1 - \alpha$	β
	α	$1 - \beta$

$$\alpha = A / B, \beta = C / D.$$

A = 実際に病気であるのにシステムが病気でないと判断した患者数

B = 実際に病気である患者数

C = 実際に病気でないと判断した患者数

D = 実際に病気でない患者数

図3 α -errorと β -errorの概略

表1 患者数の多い病名及び全病名の平均の診断結果

出力ユニットNo.	No. 4	No. 5	No. 6	No. 8	No. 10	No. 12	No. 19	No. 20	平均
α -error	0.56	0.5	0.64	0.5	0.21	0.17	0.33	0.21	0.68
β -error	0.31	0.29	0.14	0.36	0.48	0.27	0.26	0.23	0.13
患者 数	試験データ	16	2	14	14	42	6	9	14
	学習データ	55	27	25	45	121	22	23	75
									6.8
									24.3

2. 5 隠れユニット数と診断能力の関係

一般に、隠れユニット数が増えると認識能力は向上するが、ある程度に達するとそれ以上隠れユニット数を増やしても認識能力は向上しなくなることが知られている。また、最適な隠れユニットの個数は問題領域の特徴に依存し、現時点では、一般にその数を決定する方法は存在しない[7]。そこで、実際に隠れユニットの個数を変化させ、診断能力の変化を調べてみた(図4)。但し、診断を最も患者数の多い筋収縮性頭痛の判定に限定した。また、ここで利用した正答率は、全患者数に対する、病名の判定に成功した患者数の割合である。また、学習デ

ータ数を300、試験データ数を94とした。

図4より、隠れユニットの数が増えると、一般に認識能力が向上する傾向にあることが判る。また、本実験では、最適な隠れユニットの個数は72個前後であると予想される。

本実験の学習段階で、隠れユニットのある全てのネットワークは全パターンを100%正確に学習できた。しかし、パーセプトロン（隠れユニット数=0）は200パターンを100%正確に学習できたにも拘わらず、300パターンのうち4パターンを正しいマッピングに学習することができなかった。そこで、パーセプトロンを用いて形成される決定境界が超平面であることを考慮すれば、パターン数の増加により、パーセプトロンは適当な決定境界を形成できなくなったと考えられる。即ち、この病名の決定境界は明らかに超平面ではないことが判った。

2.6 学習パターン数と診断能力の関係

診断を筋収縮性頭痛の判定に限定し、学習パターン数を変えたときの診断能力を調べてみた（図5）。但し、学習データは始めの100パターンに異なる100パターンを加えて200パターンとし、さらに異なる100パターンを加えて300パターンとした。正答率は3.5節と同じである。また、ネットワークの構造や結合の重みの初期値、及び試験データ（94パターン）は同一とした。

図5より、学習パターン数100のものは他と比較すると、閾値が小さいときは診断能力があまり変わらないが、閾値が大きくなるに従い、診断能力が落ちていることが判る。これは、学習パターン数を増やすことにより病名の判定に必要な特徴的症状をはっきりと抽出できるようになつたためであると考えられる。また、学習パターン数300の閾値が0.6のときはその正答率が比較的良くなっている。これは、パターン数の増加に伴い決定境界がさらに非線形となり、閾値を0.6に設定したときに非線形の決定境界がうまく診断に影響したと考えられる。学習パターン数200と300を比較すると、学習パターン数300の方が高い診断能力であるが、閾値が0.6のときは除けば、残りの閾値では診断能力はあまり向上していない。しかし、本システムと同規模程度のNETtalkではその初期段階よりおよそ千語、即ち数千パターンを学習データとしているのと比較すると、本システムで学習に利用した患者数は明らかに少ない。従って、学習パターンをさらに100程度増やしても診断能力の向上はあまり期待できないが、学習パターンを数千くらいにすれば診断能力の向上が期待できる。

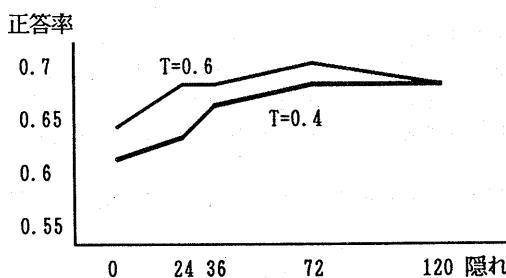


図4 隠れユニット数と正答率の関係

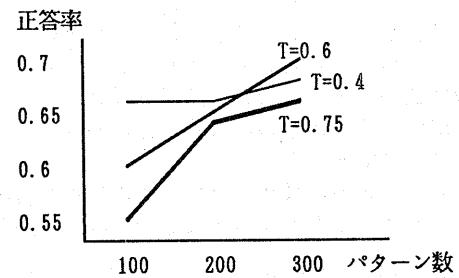


図5 パターン数と正答率の関係

2.7 PDP診断システムの考察

以上述べた項目以外に、以下の点を考察する。

(1) 診断の限界

本システムは、患者の診断全体から見ると、抽出された症状から病名を判定している。しかし、患者の思い違い等のため症状を正確に抽出できない可能性があり、また、経験を積んだ医者でも、患者の複数の病名を問診だけで完全に正答できる割合は77%程度と言われる。故に、本システムでは、複数の病名を完全に診断できる割合の上限は70%程度であると考えられる。

(2) ネットワークの構造

本稿では、隠れユニットの数を変えることにより診断能力の変化を調べたが、ネットワークを3層から4層にすることにより完全に分離した入力を同一の出力にマッピングできることが

知られている[7]。本システムの場合でも、さらに多くの患者データを学習させるときには有望な手段になると考える。

3. 記号表現との関係

3. 1 関係パラメータの獲得と評価

PDPモデルを用いて診断に関する知識の原形を与えることができる。医療診断支援システムでは、医師が症状と病名の数多くの関係（約8000個）を与える。それが、たとえ原形（0次近似）でも自動的に与えられれば大変便利である。本稿では、摂動法の考え方方に類似した2つの異なる方法を用いて関係パラメータを抽出した。そして、医師から抽出した関係パラメータ（RF）、2つの異なる方法を用いて抽出した関係パラメータ（RF₁、RF₂）、及びペーセプトロンの結合の重みから抽出した関係パラメータ（RF_p）をそれぞれ比較してみた。以下に関係パラメータの抽出法を示す。

第1の方法では、全ての入力ユニットをオフしたときのj番目の出力ユニットの活性化値をB_jとし、また、i番目の入力ユニットのみをオンにしたときのj番目の出力ユニットの活性化値をA_{ij}としたとき、i番目の症状とj番目の病名の関係パラメータRF_{1 ij}を、

$$RF_{1 ij} = (A_{ij} - B_j) \times 200$$

と算出した。但し、200を掛けたのは単にRFとのスケールを合わせるためである。

第2の方法では、学習に利用した患者毎にその症状データを入力ユニットに入れる。そして、k番目の患者に対して、もし i 番目の入力ユニットがオンであったら、そのユニットをオフにしてもう一度出力を計算し、j番目の出力ユニットに対する出力の差をD_{ij(k)}とし、もし i 番目の入力ユニットがオフであったら、D_{ij(k)}を0とする。また、全てのkに対して、D_{ij(k)} ≠ 0となるkの個数をN_{ij}としたとき、関係パラメータRF_{2 ij}を

$$RF_{2 ij} = (\sum D_{ij(k)} / N_{ij}) \times 600$$

と算出した。但し、Σは全てのkに対する和であり、600を掛けたのは単にスケールを合わせるためである。

ペーセプトロンでは、i番目の入力ユニットとj番目の出力ユニットの結合の重みをw_{ij}としたとき関係パラメータRF_{p ij}を

$$RF_{p ij} = w_{ij} \times 30$$

と算出した。但し、30を掛けたのは単にスケールを合わせるためである。

第1の方法と第2の方法を比較すると、第1の方法では、単に1つの症状を考えたとき、この症状の病名への影響が関係パラメータであると考える。一方、第2の方法では、1つの症状と病名の関係は他の症状との組合せにより変化することを想定し、それらの平均値が関係パラメータであると考える。

最も基本的な質問項目に対する最も患者数の多い病名について、各方法を用いて抽出した関係パラメータどうしの比較をしてみた（図6）。

質問項目：“その頭痛はいつから始まりましたか？” 病名 筋収縮性頭痛

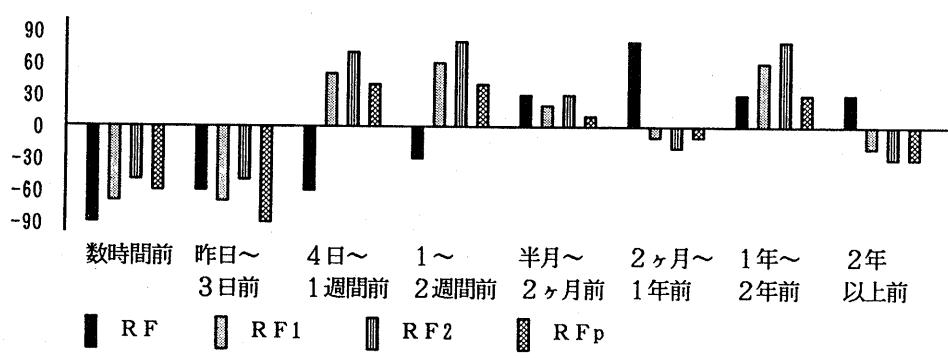


図6 関係パラメータの比較

関係パラメータどうしの適合度を調べるために、全ての質問項目の相関係数を求めてみた。その結果、RFに対するRF1、RF2、RFpそれぞれの相関係数はどれも殆ど0であった。その理由として、医師の持っている知識とシステムが獲得した知識に若干のずれがあると考えられる。例えば図6より、筋収縮性頭痛は短期的には症状が現れず、中期的に症状が現れてくる病名であることが判るが、医者の知識とシステムから抽出した知識を比較すると以下の違いが判る。まず、医者は短期と中期の境界を2週間程度と考えたのに対し、システムは4日としている。また、医者は病名の可能性を肯定するピークを1つ（2ヶ月～1年前）と考えたのに対し、システムは2つ（4日～2週間前、1年～2年前）としている。さらに、医者は長期的（2年以上前）に症状が現れる可能性を若干肯定したのに対し、システムは若干否定している等である。また、RF1、RF2、RFpはそれぞれ互いに高い相関を示した。即ち、RFpが純粋な統計量に近いことを考慮すれば、本システムはかなり線形システムに近いものと考えられる。しかし、3.5節で述べたようにパーセプトロンの学習が困難に成了したことからも決定境界は複雑であると考えられるので、学習する患者データ数を増やしたときに各抽出法の特徴が現れる可能性があると考える。

3.2 ルールの抽出と評価

患者の選んだ症状を条件部、患者の病名を結論部と考えれば、それらは全てルールの原形と考えられる。しかし、これでは単に一人の患者の特殊ケースを扱っているだけである。そこで、各患者から診断に強く効いている症状の組合せを選ぶことにより、一般的なルールを抽出することができると考え、その方法を検討した。

まず、抽出法には次の点が要求される。

- ・抽出したルールの条件部が多過ぎると一般性を失う。
- ・殆ど起らない条件の組合せを持つルールを抽出しない。
- ・抽出アルゴリズムの計算量をおさえる（可能なルールは2216通り）。

そこで、実際の患者が選んだ症状から任意の3つ以下の組合せを選び、さらに、それらの中で診断に強く効いている症状の組合せを選び、それをルールとする方法を考案した。この方法も摸動法の考え方方に類似した方法と考えられ、アルゴリズムは以下の通りである。

ステップ1：単独肯定症状の選出

1つの症状が単独で病名をオンさせるものを選出する。

ステップ2：2つ組否定症状の選出

ステップ1の症状と組となってもその病名をオフさせる症状を全ての症状から選出する。

ステップ3：2つ組肯定症状の選出

ステップ1の症状以外で、2つの症状が組になると病名をオンさせるものを選出する。

ステップ4：3つ組否定症状の選出

ステップ2の症状と組となってもその病名をオフさせる症状を全ての症状から選出する。

ステップ5：3つ組肯定症状の選出

ステップ1、2の症状以外で、3つの症状が組になると病名をオンさせるものを選出する。

このアルゴリズムを用いて筋収縮性頭痛を判定する443個のルールを抽出した。その内303個が病名をオンするルールであり、140個がオフするルールであった。以下に抽出したルールの例を示す。

if (一日中頭が痛い) then (筋収縮性頭痛である)

if (以前の頭痛は3年以上前にあった) and

(頭痛のひどいときは我慢できない程の激痛) * then (筋収縮性頭痛ではない)

if (頭痛はこめかみにある) and (なんとなく頭痛を感じ始めた)

then (筋収縮性頭痛である)

if (以前にも同じような頭痛があった) and (ストレスで頭痛がひどくなる) and

(頭痛はアルコールで誘発される) * then (筋収縮性頭痛ではない)

i f (頭痛は1~2週間前から始まった) and (頭痛のひどいとき鈍痛) and
 (ひとねむりすると軽くなる) then (筋収縮性頭痛である)
 但し、*は病名に否定的に働く症状である。

次に、抽出したルールを評価するため、抽出したルールにより筋収縮性頭痛の判定を行った。そのために、ルールの適用法として優先順位を、

単独肯定 > 2つ組否定 > 2つ組肯定 > 3つ組否定 > 3つ組肯定
 とし、マッチするルールが無いものは病名を否定したと解釈した。そして、未知の患者52人に対して行った診断結果を示す(表2)。

表2より、抽出したルールによる実際の病名に対する診断結果、及び抽出したルールによるシステムの診断に対する評価は、共にあまり良くない。特に β -errorが大きくなっている。その理由として、否定に関するルールの抽出法やルールの適用法に問題があったと考えられ、今後の改良が必要とされる。また、抽出したルールを人間が統計処理することにより、診断能力が向上することも期待される。

()内は患者数、閾値は0.6に設定

表2 ルールの適用結果

参考

ルールによる実際の病名に対する診断結果		ルールによるシステムの診断に対する評価		システムによる診断結果		パーセプトロンによる診断結果	
α -error	β -error	α -error	β -error	α -error	β -error	α -error	β -error
0.38 (9)	0.50 (14)	0.17 (4)	0.34 (10)	0.33 (8)	0.25 (7)	0.38 (9)	0.36 (10)

4. おわりに

本稿では、PDPモデルの知識処理への適用性を明らかにするため、同モデルに基づく診断システムを作成し、その能力、可能性について報告した。即ち、PDPモデルによる頭痛診断システムの構成、学習、及び未知の患者に対する診断結果を述べ、同システムの診断能力を考察した。また、PDP診断システムが獲得した知識（関係パラメータ）と医者から抽出した知識を比較し、さらに、PDP診断システムからのルールの抽出法を検討した。

今後は、ネットワーク構造を3層から4層へ変えることによる診断能力の変化、4層のネットワークの表現能力、及び、ルール抽出法の改良によるPDPモデルと記号処理との関係について解明して行きたい。

謝辞 医療診断支援システムについて教えて戴いた津村宏主任研究員に感謝致します。

参考文献

- [1] 大須賀節雄、佐伯胖共編：知識工学講座3、知識の獲得と学習、オーム社(1987)
- [2] D. E. Rumelhart, J. L. McClelland and the PDP Research Group, "Parallel Distributed Processing", Vol. 1, MIT Press, (1986).
- [3] D. E. Rumelhart, G. E. Hinton, R. J. Williams, "Learning Representation by Back-Propagating Errors", Nature, Vol. 323, Oct. 9, (1986).
- [4] T. J. Sejnowski and C. R. Rosenberg, "NETtalk:A Parallel Network that Learns to read aloud", Johns Hopkins Univ. Technical Report JHU/EECS-86-01, (1987).
- [5] 益沢秀明他 "医療知識ベースの利用による医療診断支援システム(DOCTORS)の臨床評価", 第4回医療情報連合大会, (1984).
- [6] C. Stanfill and B. Kahle, "Parallel Free Text Search on the Connection Machine System", CACM 29, 12, (1986).
- [7] R. P. Lippmann, "An Introduction to Computing With Neural Nets", IEEE ASSP Magazine April , (1987).