

氏名	富川 義弘
生年月日	
本籍	富山県
学位の種類	博士(工学)
学位記番号	博甲第228号
学位授与の日付	平成9年9月30日
学位授与の要件	課程博士(学位規則第4条第1項)
学位授与の題目	リカレント形ニューラルネットワークの収束制御方法とパターン写像への応用
論文審査委員	(主査) 中山 謙二 (副査) 松浦 弘毅, 橋本 秀雄, 船田 哲男, 村本健一郎

学位論文要旨

A recurrent neural network is a type of neural network models which has feedback loops from output to input. This model has various useful properties. It is however known that it is difficult to control the network dynamics.

In this study, some types of this networks are applied to many valued mapping approximation, combinatorial optimization problems and shape recognition. The convergence properties of this network are considered for each application.

For approximating many valued mapping, a multi layer neural network with a feedback loop is used. This model can approximate many valued output as convergent state of the network. It is proposed how to learn this convergence property on the network.

Combinatorial optimization problems are to find the solution which *minimizes the objective function* under the constraint conditions. For this applications, a fully connected single layer neural network is used. It is investigated how to give the constraint conditions to the network. Especially, the constraint neuron is proposed to give an linear inequality condition.

In addition, the diagonal element control method is theoretically analyzed. The diagonal elements are of the connection weight matrix and mean the self feedback loop of the neuron in the network. It is known that the convergence probabilities to optimal solutions are improved by using this method.

For shape recognition, a feature corresponding model, using a fully connected neural network with the constraint neurons, is proposed. Constraint neurons permit 0-1 or 1-0 correspondence. By using constraint neurons, the proposed model can have the performance of selective attention and selective recognition.

ニューラルネットワークは、神経細胞の機能を模倣したモデルを利用して、生物の情報処理機構を実現しようとする研究である。最近、この分野において、フィードバック機構を取り入れたリカレント形モデルが提案されるようになってきた。図1は、リカレント形ニューラルネットワークの2つのタイプを示したものである。図1(a)は、層構造を持たないネットワークで、相互結合形ニューラルネットワークと呼ぶ。また、図1(b)は、層構造をもつニューラルネットワークにフィードバック機構を取り入れたもので、フィードバック付き階層形ニューラルネットワークと呼ぶ。リカレント形のニューラルネットワークは、様々な特性を持ち応用性も高い。しかし、ダイナミクスを持ち、その収束特性の制御は一般的に難しい。本研究では、パターン写像に関するいくつかの応用に対して、ネットワークの収束特性を制御する方法を検討する。

1章では、ニューラルネットワークに関する基本的な概念、リカレント形ニューラルネットワークの構造、及び、リカレント形ネットワークを扱う上で必要となる力学系の基本をまとめる。

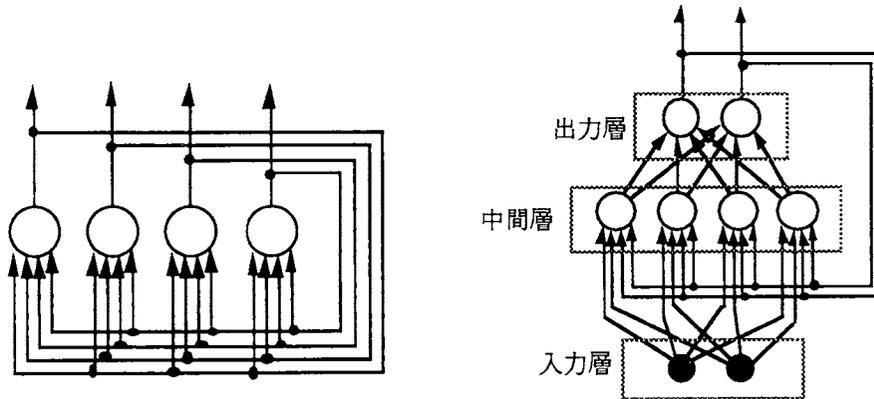


図1(a) 相互結合形ニューラルネットワーク

図1(b) フィードバック付き階層形ニューラルネットワーク

図1 リカレント形ニューラルネットワークの構造

2章では、フィードバック付き階層形ニューラルネットワークを多価写像近似に適用する。写像近似とは、与えられたデータを補間する写像関係を求めることである。この応用は、階層形モデルの写像近似能力とフィードバック機構の持つ多値収束性を利用したものである。

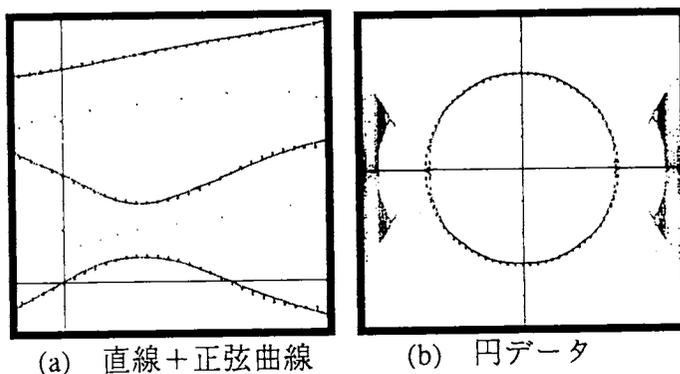
多値性のある $x^* \rightarrow y^*$ の写像を学習するために、フィードバック入力の代わりに、教師データ y^* を入力に与えて、 $(x^*, y^*) \rightarrow y^*$ の関係を学習する。想起段階では、ネットワーク出力を入力にフィードバックして、 $y(n) = f(x, y(n-1))$ の収束点を検出する。これは、逐次代入法による $y = f(x, y)$ の非線形数値解法に相当する。

逐次代入法では一般に解への収束特性は保証されず、収束性は関数 $f(x, y)$ に依存する。関数 $f(x, y)$ は、ネットワークの出力関数である。この収束特性を制御するために、上記の学習法に加え偏微分条件を導入する。

偏微分条件とは、学習点近傍でのネットワーク出力関数のフィードバック入力に対する偏微分値を1以下になるように制約するための条件である。

さらに、スプリアスな解への収束を抑制し、より広範囲の引き込み領域を実現するために、積分条件を学習時に付加する。積分条件とは、学習点以外の初期値が、学習点に収束するように、出力関数に制約を与えるための条件である。この条件は、積分形の条件式となる。学習は、誤差逆伝搬法を改良して、偏微分条件と積分条件を含めた誤差関数の最小化を行う。

図2は、フィードバック付き階層形ニューラルネットワークによる多価写像の近似結果である。*印の学習点に対し、一様な初期値からネットワークを動作させ、その収束点を・でプロットした結果を示した。



(a) 直線+正弦曲線

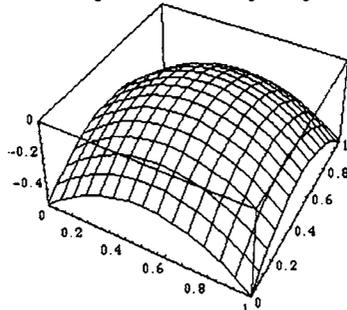
(b) 円データ

図2 曲線データの近似

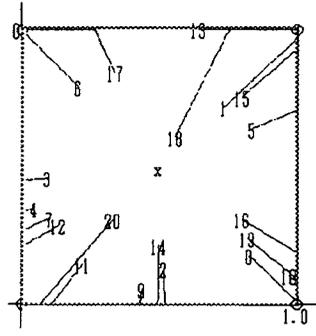
3章では、相互結合形ニューラルネットワークの組み合わせ最適化問題への応用を考え、等号・不等号の制約条件をネットワークに取り入れる方法を考察する。相互結合形ニューラルネットワークは、目的関数を最小化する二値の状態ベクトルを求めるといった組み合わせ最適化問題の解法に利用される。従来、組み合わせ最適解の解法において、

等号の制約条件に関しては提案されているが、制約条件に関する重み係数という調整項が必要であった。本研究では、重み係数の影響しない等号制約条件の取り入れ方を、過去の研究事例より考察した。さらに、制約ニューロンを提案し、制約条件を線形不等号条件まで拡張した。

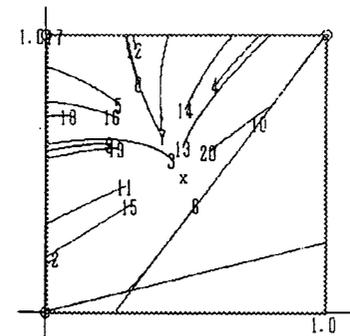
$$E(x,y) = -x^2 + x - y^2 + y - 0.5$$



凸形のエネルギー関数



(a) 制約条件がない場合



(b) 制約条件がある場合

図3 二次元のエネルギー関数を用いた場合の状態変化と不等号制約条件

制約ニューロンは、与えられた不等号条件に対してニューロンを割り当て、ニューロンの飽和性を利用して、不等号条件の制約をネットワークに与える方法である。

図3は、二次元のネットワークで、制約ニューロンの効果を示したものである。ネットワークのエネルギー曲面が上に凸形になるように結合係数を設定した。このネットワークの状態空間は、エネルギー曲面図の底面に相当し、図3(a)、(b)の四角になる。二値解は、4つの頂点に相当する。制約ニューロンを含まない場合は、図3(a)のように、状態空間中心から拡がるように状態変化し、4つの頂点に収束する。収束点は、(○)で示される。これに対し、図3(b)は、制約ニューロンを用いた場合で、図中の直線の上側が与える不等号制約である。ネットワーク内での状態変化は制約され、収束点は、4点から3点に減少した。この制約ニューロンの導入により、相互結合形ニューラルネットワークが、不等号条件を満たすように状態変化することが確認できる。

4章では、相互結合形ニューラルネットワークにおいて、最適解の検出確率を高める手段として提案されている対角項操作を理論的に解析する。解析は、引き込み領域の変化と頂点の安定性の変化に着目する。

引き込み領域の解析では、まず、エネルギー関数の固有値分解から、固有超平面の概念を導出する。固有超平面は、ネットワークの状態変化に対し、固有値が負の場合は分岐面、固有値が正の場合は集約面として作用する。さらに、対角項操作によって、分岐面として作用する負の固有超平面が、状態空間中心の上り勾配側に移動することを示す。この固有超平面の移動によって、状態空間中心の下り勾配側の引き込み領域が増加することになる。

また、頂点安定性の解析では、頂点の安定性を示す指標として、頂点安定率を定義する。この頂点安定率を用いて、対角項操作によってすべての頂点の安定性が単調に失われ、安定性の高い頂点への収束確率が高くなることを示す。さらに、頂点におけるエネルギー関数値と頂点安定率を比較することによって、対角項操作によって最も安定な頂点と最適解とは、一致しないことを示す。

これらの解析から、対角項操作は、通常、最適解の検出確率を高くするが、最適解だ

けが安定な頂点として存在するネットワークは、必ずしも保証されないことがわかった。

5章では、従来の相互結合ニューラルネットワークを用いた対応づけ形状認識モデルに制約ニューロンを導入したモデルを提案する。対応づけ形状認識モデルとは、入力側の特徴と記憶側の特徴を対応づけることによって、対象物の回転や位置ズレに影響されない認識を実現するモデルである。対応づけ形状認識モデルの考え方は、従来よりあるが、基本的に特徴どうしが、1対1対応する問題しか扱われていない。制約ニューロンを導入し、不等号制約を取り入れることによって、従来の1対1対応に加え、0対1、1対0の対応関係を許容することができる。

図4は、提案する対応づけ形状認識モデルを用いて、線分の特徴で構成されるピラミッド形の入力情報から、三角形の記憶情報を認識させた結果である。図左下のマトリックスが、対応づけを行う相互結合形ニューラルネットワークのニューロンの活性値、マトリックスの上と右側にあるのが、制約ニューロンの活性値を示している。

ネットワークを適当な初期値から動作させると、相互結合形ニューラルネットワークの状態変化によって、収束する。収束状態が、対応づけの結果である。この例では、初期値を変えることで、異なる対応づけパターンが検出された。図4の例では、3通りしか示されていないが、実際は4つの三角形がすべて認識された。

また、表1は、入力と記憶の構成要素数が一致するz形と、一致しないピラミッド形の例で、収束点の正解率を比較した結果である。1対1の等号条件では、z形は認識できてもピラミッド形を認識することはできない。これに対して、制約ニューロンを導入し、不等号条件を許容することで、ピラミッド形の例でも認識可能となる。このピラミッド形のシミュレーション結果は、提案モデルが、単に形状認識能力をもっているばかりではなく、選択的注視能力もあわせもっていることを示している。

これらの応用例から、リカレント形ニューラルネットワークの収束特性を適切に制御することによって、従来のフィードフォワード形モデルでは、難しかった多くの問題が解決できることがわかった。しかし、制御が不十分な場合、カオスなどの不規則減少が現われることがある。この境界は、未だ明確にはなっておらず、今後の課題として残されている。

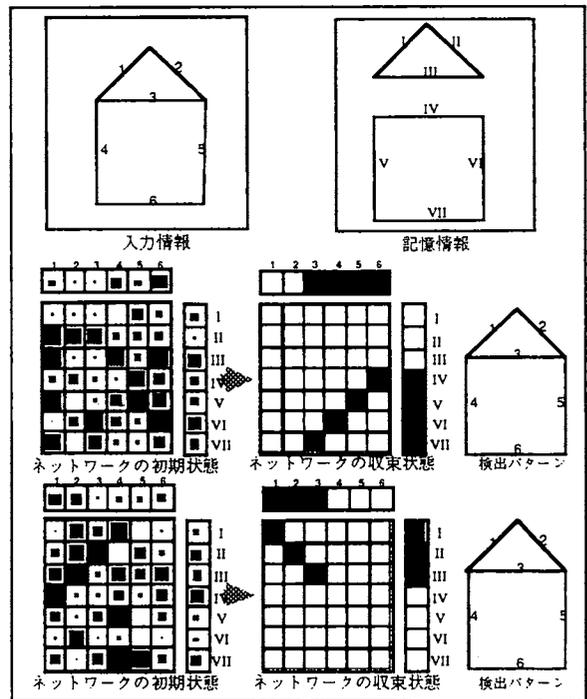


図4 家形からの四角形・三角形の認識

	制約条件なし	等号制約条件	不等号制約条件
z形 パターン	0%	100%	100%
ピラミッド 形パターン	0%	0%	100%

表1 不等号条件モデルと等号条件モデルの比較
(収束パターンの正解確率)

学位論文審査結果の要旨

平成9年7月28日に開催された第1回学位論文審査委員会、及び平成9年8月6日に行われた口頭発表と第2回学位論文審査委員会で審査した結果、以下の通り判定した。

本論文は、部分的、または全体としてフィードバックを有するリカレント形ニューラルネットワーク (RNN) において、そのダイナミクスの収束制御法及び解析法を提案し、応用における有効性を示している。まず、1価変数を多価関数に写像するネットワークと安定な引き込み特性を実現する学習法を提案し、シミュレーションにより価数変化がある関数や不連続関数への写像も可能であることを示している。次に、ニューロンの自己ループ、即ち結合行列の対角項操作とエネルギーが最小な最適解への収束性の関係を理論的に解析し、収束確率が高い安定な解と最適解の対角項依存性を明らかにした。最後に、RNNを用いて組合せ最適化問題を解く際の制約条件を、従来の等号条件から制約ニューロンを導入することにより不等号条件に拡張する方法を提案した。この方式を形状認識に応用し、ある形状を複数個含む全体のパターンから当該形状を可能な組合せで認識できることを確認している。

以上の研究成果は、RNNのダイナミクスによるパターン写像について、収束の制御法を提案するとともに、その収束過程を理論的に解明したものであり、ニューラルネットワークの研究に学術的にも実用的にも寄与するところ大であり、本論文は博士論文に値するものと判定する。