

シヨートノート

フィードバック付き多層ニューラルネットワーク†

古谷立美^{††} 秋山 泰^{††}
田中敏雄^{††} 新田 徹^{††}

フィードバックリンクを持った多層ニューラルネットワークを提案し、二つの応用形態を示す。第1の利用形態は自己想起連想メモリであり、第2は汎化能力の高い多層ネットワークである。自己想起連想メモリは、相互接続を持った2層ネットワークで、強い自己想起力が実現できる。汎化能力の高いニューラルネットワークは、中間層と出力層間に相互接続を持つ多層ネットワークで、強い汎化能力を持つ。これらのネットワークの学習にはバックプロパゲーションが利用できる。

1. はじめに

フィードバックリンクを持つ多層ニューラルネットワークは今までにいくつか提案されてきた。BAM¹⁾は対称相互結合を持ち双方向連想を実現した。文献2)は連続値を想起する2層のネットワークで、中間層の活性値をあらかじめ決めておく学習法を提案している。本論文で提案するフィードバックリンクを持つ多層ニューラルネットワーク(以下、FM ネットと略)はそれらの一般形である。以下ではまず、このネットワークに対するバックプロパゲーション学習法を示す。次にFM ネットを用いた連想メモリ³⁾と分類ネットワークの応用を示す。

2. フィードバックリンク付き多層ニューラルネットワーク

図1が、ここで提案するFM ネットの基本形である。ネットワークは入力層、中間層、出力層よりなり、図1(a)のように出力層から第1中間層(入力層に隣接する中間層)にフィードバックリンクを持つ。図1(b)は図1(a)と等価なネットワークであり、学習の説明を容易にするために使用する表現法である。すなわち、入力層は“仮の入力ユニット部”と“真の入力ユニット部”の二つの部分よりなる。仮の入力ユニットは出力層の各ユニットに対応し、対応する出力ユニットから重み“1”でフィードバックを受ける。入力ユニットはしきい値を持たず、ただ入力を中間ユ

ニットに分配する働きをするだけなので、仮の入力ユニットは出力ユニットと共通にすることができる。そのため、仮の入力ユニットは省略することができる。図1(a)と等価になる。

このネットワークの学習法の基本は、まず出力ユニットから“仮の入力ユニット”へのフィードバックリンク(点線)を取り除き、単なる多層ネットワークと考え、入力層(仮の入力ユニットと真の入力ユニット)と出力層に入出力パターンを与えてBP学習を行う。学習終了後、仮の入力ユニットの省略を行う。すなわち、仮の入力ユニットから第一中間層へのリンクを出力層から第一中間層への直接接続に置き換える。具体的学習法は以下に示す。相互結合型ニューラルネットワークの動作法には、同期式と非同期式があるが、前者は発振を起こすことが多いため、以下では非同期動作を用いる。

3. 二つの典型的な利用形態と学習法


ここでは、FM ネットの二つの典型的な利用形態と学習法を示す。なお、以下では3層の多層ネットワークを例に用いる。

3.1 自己想起型連想メモリ


第1の利用形態は自己想起を行う連想メモリである。ネットワークの構造は図1から真の入力ユニットを取り去ったもので図2(a)のようなニューラルネットワーク(NN)になる。図2(a)では、フィードバックリンクを単純化して双方向矢印で示しているが、双方向矢印の重みは対称ではない。これを自己想起型連想メモリとして使う場合は、出力層のみを連想メモリのユニットと考え、ここに連想パターンを記憶させる。当然

† Multi-layer Neural Network with Feedback Links by TATSUMI FURUYA, YUTAKA AKIYAMA, TOSHIO TANAKA and TOHRU NITTA (Computation Models Section, Computer Science Division, Electrotechnical Laboratory).

†† 電子技術総合研究所情報アーキテクチャ部計算機研究室



(a) ネットワーク構成
(a) Network structure.




● 仮の入力ユニット
○ 真の入力ユニット
(b) (a)と等価なネットワーク
(b) Equivalent network of (a).


図1 FM ネットの基本構成
Fig. 1 Basic structure of neural network.

中間層もパターンの記憶に関与するが、あくまでも中間層は隠れ層で、連想メモリとして使う場合は出力ユニットのみからなるメモリとして使用する。自己想起型連想メモリでは学習した連想パターンの一部を与える(クランプする)と記憶したパターン全体を想起する。

この場合の学習は、まず図2(b)のネットでフィードバックループを取り去り、記憶パターンを入力層と出力層に与えて(入力パターンと出力パターンは同じ)BP学習を行う。学習が済んだ後、仮の入力ユニットから中間層へのリンクを出力層から中間層のリンクに張り替えて学習が終わる。このようにしてできあがった図2(a)のネットは、相互結合を持ったNNで、学習パターンが安定点(ローカルミニマム)を作る。すなわち、NNが安定点に引き込まれることを利



(a)



(b)

図2 自己想起型連想メモリ
Fig. 2 Auto-associative memory.

用して自己想起を行う。学習パターンが安定点になることを調べるため、次に示す三つのNNについて学習の結果どのような安定点ができるかを調べた。

- ①中間、出力層とも15ユニット。
- ②中間層12, 出力層15ユニット。
- ③中間、出力共15ユニットであるが、各層5ユニットずつの3ブロックに分け、中間層から出力層への接続は同一ブロック内へ、出力層から中間層への接続は他のブロックのユニットだけに限定したもの。

実験は三つのNNに“0”と“1”からなる10パターンを5組用意し学習させた。5組のうち最初の2組は筆者らが作った規則性のあるパターン、残りの3組は乱数で作ったものであり、5組とも直交しないパターンである。表1は5組の連想パターン(各組10パターン)に対して、15ビットで実現できるすべての初期値からNNを動作させ安定点の数を調べたものである。この結果学習パターンはすべて安定点となった。しかも学習パターン以外の安定点は非常に少ないことがわかる。図3は、自己想起力を求めたもので、上記の三つのNNに対し、記憶しているパターンのうち何ビットを与えると全体の記憶パターンを想起できるかを示している。この結果、15ビットのうち6~7ビット与えると90%以上想起することがわかる。

表1 安定点(ローカルミニマム)の数
Table 1 Number of stable point (local minimum).

パターンの組とパターンの性質 (平均ハミング距離/平均角度)	1 (6.9/63.3°)	2 (9.2/80.3°)	3 (7.4/69.0°)	4 (7.9/57.9°)	5 (7.9/63.2°)
①の NN	13	13	16	14	16
②の NN	11	18	22	14	12
③の NN	10	10	12	10	12




図3 自己想起力
Fig. 3 Capability of auto-association.

3.2 中間出力間に相互結合を持つ多層ニューラルネット

第2の利用形態は、普通多層NNと同様な使い方、入力層にパターンを与え出力層に出力パターンを導くものである。このNNを各ユニットの初期値設定に、普通多層NNの結果を利用することにより、強い引き込みを実現する。図4(a)がこの例で、普通多層NNとの違いは、出力層から中間層にフィードバックがある点である。このネットの学習は、まず図4(b)からフィードバックリンク(点線)を除いた多層NNに対してBP学習を行う。この時、学習に使う入力パターンは“真の入力へのパターン”と“仮の入力へのパターン”からなり、“真の入力への入力パターン”は図4(a)の入力に与えられる入力パターンであり、“仮の入力への入力パターン”は図4(a)の教師出力パターンと同じものである。このようにして学習した後、仮の入力ユニットから中間層へのリンクの重みを図4(a)の出力層から中間層への戻りリンクの重みにセットする。このNNはフィードバックがあるため、ユニットの初期値が結果に影響を与える。そのため強い引き込みを実現するには、起動時に各ユニットの初期値(活性値)をうまく与える必要がある。初期値の決め方はまず、ここで用いるFMネットと別の、フィードバックのない多層NN(以下Mネットと略)を用意し、FMネットに用いるものと同じ学習データでBP学習を行う。FMネットを動かす時は、まずMネットにFMネットと同じ入力を与え出力ユニットの活性値を求め、これをFMネットの出力ユニットにセットする。次にFMネットに入力を与え、入力データと先に求めた出力ユニットの値から中間ユニットの初期値を決め、しかる後にFMネットを非同期動作させ出力を求める。





図4 引き込みの強い多層ネット
Fig. 4 Neural network with generalization.




図5 引き込みの強さ
Fig. 5 Generalization.

引き込みの強さを調べる実験として、図4(a)のネットに各層10ユニットのNNに“0”と“1”からなる10のパターンを学習させた後、教師データと何ビットか異なる入力パターンを与え、学習データを正しく出力できるかを調べた。ここでの教師データは表1に用いた記憶パターン15ビットから10ビット選んだものを用いている。図5がその結果で、横軸がテストデータと教師データとのビットの違い、すなわちハミング距離であり、縦軸が学習データを正しく出力した割合である。図5の○-線がFMネットに初期値を上の方法でセットしたもの、△-線はFMネットの初期値をランダムにセットしたもの、□-線がフィードバックのない普通多層ネットの結果である。これから、フィードバックのあるものが非常に強い引き込みを示すことがわかる。

4. おわりに

フィードバック付き多層NNを提案し、二つの典型的な利用形態と学習法を示した。このNNはBP学習が使える、安定点をかなり意図的に作り出せる。状態が安定点へ収束するための条件は、文献2)の証明がそのまま適用でき、出力層または中間層の活性状態が0または1に非常に近い値を取ることである。本論文の実験では学習パターンに1/0の値を用いたためこの条件を満足していた。連続値を学習させる場合には、中間層が1/0値に近づくように注意する必要がある。中間層を1/0値に近づける方法としてはシグモイド関数の傾きを学習の進展に伴って急峻化したり、中間ユニットの数を変える等の方法が考えられる。3.1節のネットワークは強い自己想起力を示し、3.2節の多層NNは強い引き込みを示した。FMネットは、3.1節の①②③に示したように、様々な変型が可能で、今後様々な分野に利用できると思われる。

謝辞 本論文で参照している文献2)は、査読していただいた方から紹介された。この論文のおかげで、FMネットの収束が議論でき、理論的背景を与えることができた。ご査読いただいた方に深く感謝いたします。

最後に本研究の機会を与えられた棟上情報アーキテクチャ部長に感謝いたします。

参 考 文 献

- 1) Kosko, B.: Bidirectional Associative Memories, *IEEE Trans. System, Man and Cybernetics*, Vol. 18, pp. 49-60 (1988).
- 2) Atiya, A. and Abu-Mostafa, Y.: A Method for the Associative Storage of Analog Vector, in *Advances in Neural Information Processing Systems 2*, Touretzky, D.S. (ed.), pp. 590-595, Morgan Kaufmann Pub. (1990).
- 3) 古谷ほか: バックプロパゲーションネットを相互接続したニューラルネットとその連想機能, 信学技報, NC 90-37 (1990).

(平成3年2月18日受付)

(平成3年6月13日採録)



古谷 立美 (正会員)

昭和22年生。昭和48年成蹊大学大学院修士課程修了。同年電子技術総合研究所入所。現在同所計算機構研究室長。工学博士。IEEE会員。



秋山 泰 (正会員)

昭和36年生。昭和59年慶應義塾大学理工学部電気工学科卒業。平成2年同大学院博士課程修了。工学博士。同年電子技術総合研究所入所。ニューラルネットワークの研究に従事。

従事。



田中 敏雄 (正会員)

昭和23年生。昭和46年日本大学理工学部電気工学科2部卒業。昭和42年電気試験所(現、電子技術総合研究所)入所。光磁気記録、垂直磁気記録、ニューラルネットワークの研究に従事。現在、情報アーキテクチャ部計算機構研究室主任研究官。電子情報通信学会会員。



新田 徹 (正会員)

1960年生。1983年筑波大学第一学群自然科学類卒業。1985年同大学院修士課程修了。同年日本電気(株)入社。1990年同社退社。同年電子技術総合研究所入所。ニューラルネットワーク、資源配分理論の研究に従事。

ワーク、資源配分理論の研究に従事。

論文誌編集委員会

委員長	名取 亮			
副委員長	村岡 洋一			
委員	石畑 清	伊藤 潔	魚田 勝臣	
*地方在住委員	浮田 輝彦	大田 友一	小池 誠彦	
	佐藤 興二	島津 明	杉原 正顕	
	高橋 延匡	徳田 雄洋	永田 守男	
	益田 隆司	三浦 孝夫	毛利 友治	
	山下 正秀	吉澤 康文	*有川 節夫	
	*岩間 一雄	*島崎 眞昭	*白井 良明	
	*白鳥 則郎	*田中 讓	*富田 眞治	
	*三井 斌友			