

ノックプロパゲーション学習の高速化 TEST & LEAP 法

6F-1

仁木 和久

電子技術総合研究所 情報科学部 認知科学研究室

1. はじめに

バックプロパゲーション学習(BP)は、コネクションニストモデルによく使われている。BPは、学習能力が従来のアルゴリズムに比べ強力であるが、学習速度が遅い、ローカルミニマムに陥る恐れがあるなどの欠点がある。

本論では、 $1/0$ からなる目標出力パターンを、ローカルミニマムを避けて高速にBP学習させるための学習手法(TEST & LEAP法)を提案する。

2. $1/0$ からなる目標パターンのBP学習

入力パターンの弁別学習のように、 $1/0$ からなる目標出力パターンをBP学習することは多い。たとえば、連想記憶⁽¹⁾やXOR関数などの学習もこの例である。従来、BPの研究ではBP学習の内部に立ち入らなかったために、このクラスの学習と連続した値の連続した数値への写像(continuous-mapping)学習の区別をつけていなかった。しかし、このクラスの学習は、パーセプトロンのように情報空間の線形分離の問題として捉えることができ、その特徴を利用した学習の高速化が出来ることを本論では示す。

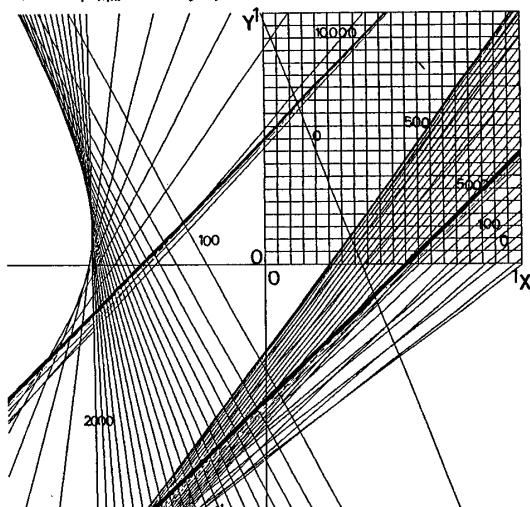


図1は、3層(2入力素子(x,y), 2中間層素子, 1出力素子)の回路でXOR関係を学習時の、2個の中間層素子の線形分離線(超平面)

$$W_x * x + W_y * y + \theta = 0$$

Hi-Speed Method for Back Propagation Learning.

-- Test & Leap Method --

Kazuhisa NIKI

Electrotechnical Lab.

の経時的な変化を示す。分離線上で、中間素子のシグモイド変換を受けた出力は0.5となる。分離線を境に、一方では分離線から離れるに従い0に近づき、もう一方では1に近づく。図中には、学習ステップ数がサンプル表示されており、この例では22000ステップで誤差が0.0002になっている。学習の初期では線形分離線が迷走しているが、早い時点(この場合1つの分離線は5000ステップで、もう一方は10000ステップ)でBP学習で獲得される情報空間の線形分離の構造がほぼ完全に決まっていることは注目に値する。この線形分離線は、グローバルミニマムの情報構造を反映している。学習誤差を小さくするために多くの学習ステップが消耗されていることを示している。

学習の構造が決まり始める時点での $|W| = W_x^2 + W_y^2$ の値は、4.5位であると考えられる。4以上である事は、シグモイド曲線の2点が弁別的に学習されるための必要条件である。⁽²⁾

3. TEST & LEAP 法

BP学習は、ローカルミニマム等の問題がなくても、一桁の学習精度を上げるために数倍の学習時間を要するという数学的性質を持っている。しかし、筆者らの見解では、学習の本質は学習の初期の段階で獲得されていると考える。

この考えを定式化した学習手法TEST & LEAPを、次に示す。

- ① $|W|$ を2程度になるように、Wをランダムに生成する。
- ② BP学習を行なう。
- ③ $|W| = W_T$ (例えば4.5)になった中間素子は、Wの全ての要素と θ をn (例えば1.5)倍し、学習の判定基準である(最終層での)自乗誤差が改善されたかTESTする。

(3.1) 最善されたときは、目的とする情報構造が部分的に獲得されたとし、学習を加速したWを新しいWとする。(LEAP)

(3.2) 改善されないときは、Wの値を①に準拠して再設定する。

- ④ 誤差評価が、最終目標に達しない場合は、②の過程に戻る。

TEST & LEAPポイントは、単純な問題に

は1点だけで十分な効果が得られるが、ローカルミニマムが有り得るような複雑な問題で正確なグローバルミニマムに収束させるには、 $W_T = 4, 5, 7, \dots$ のように複数のTEST & LEAPを徐々に行なう必要性がある。また、1つのTESTポイントで、 n を極端に大きくすると、パーセプロトロン的な線形分離線を学習する。

図1と同じ初期値に対しTEST & LEAP法を適用 ($W_T = 4, 5, n = 1, 4, 5 ; W_T = 7, 5, n = 2$) すると5000ステップで図1とほぼ同様の結果を得られる。(図省略)

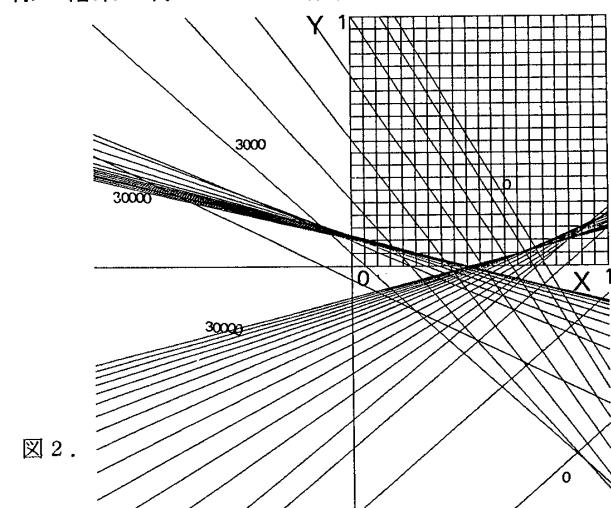


図2.

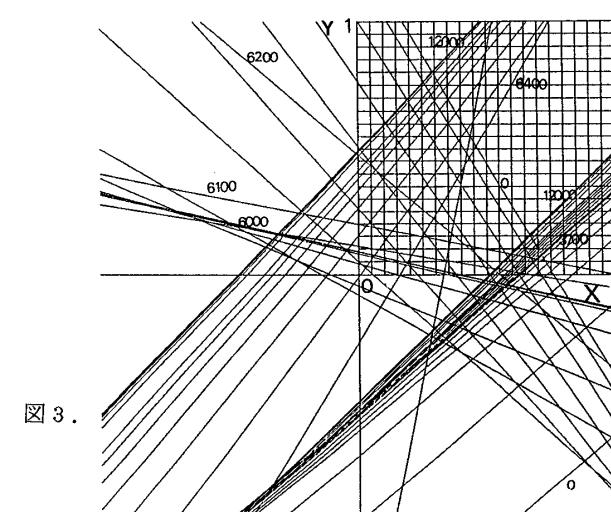


図3.

図2は、XORにおいて、BPがローカルミニマムに陥り学習が出来なくなつた状況を示す。2つの矛盾した線形分離線が出来ている。しかし、TEST & LEAP法を用いると、図3のようにXOR学習が達成される。6000ステップで2番目の中間層の素子のTEST結果が失敗であったため、その素子の結合を初期化し、ローカルミニマムを克服する。この場合、初期値が小さければ、必ず成功する。

ローカルミニマムの原因として、同じほどの勢

力を持った素子が、相互に矛盾した情報構造を確立しようと、つばぜり合いをしてる状況がある。一方がLEAPすると、均衡状態が崩れ、つばぜり合いをしていた相手方の誤りを大きく直すことにより、ローカルミニマムから抜け出せる。しかし、このようなローカルミニマムの克服は希で、図3のような克服が普通である。

4. むすび

シグモイド出力を有する入力集団に対しては1、また別の入力集団に対しては0に近づける学習状況では、2つの入力集団の中間にシグモイド出力0.5の線形分離超平面が学習の初期段階で決定していることを、TEST & LEAP法は利用している。2つの入力集団をどのように選ぶかは、BPが決定しており、TEST & LEAPは、BPが学習を進めている情報構造が大局的に正しいものかを評価し、学習を加速している。このように、TEST & LEAP法は、BPの基本的な学習能力の長所を活かし、学習の遅さやローカルミニマム等のBPの欠点を補う手法となっており、入力パターンの弁別／識別学習を行なうネットワークの学習に使うことができる。

1/0目標パターンの学習は、シグモイドの非線形領域を使っているため、連続写像のネットワークと異なり、安定した出力パターンが得られる。これは、識別やシンボル的表象のパターン表現にふさわしい特徴である。

TEST & LEAP法で達成されたことや課題は次のようにある。

- ★ 情報構造が決まった回路の学習に、無駄な学習で時間をロスさせない。
- ★ TEST & LEAP自体がローカルミニマムの検出機構、回避機構となっている。
- ★ 隠れ層に多くの素子がある場合、LEAPした素子が、その情報構造を代表する素子となり、結果として、中間層では1/0パターンを持った構造化⁽³⁾がなされる。
- ★ 素子数や層の数が増え、複雑な学習をするとき、全ての層にTEST & LEAPすべきであるが、その場合に必要な制約・手順、TESTの基準、nの大きさ等の検討が必要である。

謝辞 本研究の機会を与えられた情報科学部田村浩一郎部長、討論下さった諏訪基認知科学研究室長、石川真澄主任研究官に感謝致します。

参考文献 1) 仁木；誤差訂正学習とフィードバックを持つ自己連想記憶、63年電子情報通信学会秋期大会、2) 仁木；自己連想記憶モデルMACの提案とBPの考察、信学会第2回脳神経情報システム研究会、3) 石川；構造的コネクションモデルの試み、日本認知科学会第5回大会