

5N-1

BP法パターン認識効率の入力データ分解能依存性

西村 治彦

小山 宣樹

兵庫教育大学

1. はじめに

階層型ニューラルネットワークの学習アルゴリズム「バックプロパゲーション(BP)法^(1,2)」が提出されて以来、パターン認識に関する応用的研究が盛んに進められている。その中で、ネットワークの構造および学習に関する種々のパラメータの決定方法は、そのネットワークの学習能力を左右する重要な問題⁽³⁾として注目されてきた。具体的にはこれまで、中間層数、中間層のユニット数、結合荷重の初期値、ユニットのしきい値パラメータなどの最適化について議論されている。しかし、その場合の立場は、学習させる入出力パターンに対応する入出力層のユニット数は固定という前提のものがほとんどである。

学習パターンデータに画像的な意味で分解能を考慮する場合、分解能に応じて入力層のユニット数が変化することになる。すなわち、同一学習対象に対して、分解能毎にネットワークの構造自体を変化させざるを得ない。このような次元(トポロジー)の変化の下での最適化についての考察は、実験、理論ともまだまだ不十分なのが現状である。

そこで、本研究では、まず実験的に、入力データ分解能(入力層ユニット数)と認識学習効率の相関について検討し、他パラメータとの依存関係についても吟味を試みた。素朴な考えでは、入力パターンデータの分解能を上げれば、識別すべき各パターン間の違いが際だち、すなわち、そのハミング距離(対応ビットの異なる箇所の総数)が大きくなり、認識効率の向上につながると思われる。一方、分解能を上げることに伴う入力層のユニット数の増加は、BP法の学習アルゴリズムになんらかの負荷を及ぼすことが予想される。認識効率はこれら両者の競合によって決定され

るものと考えられる。以下、実験およびその結果、結論、今後の課題等について報告する。

2. 実験の概要

ネットワークとしては層間結合のみの3層構造とし、中間層、出力層ユニットの変換関数はシグモイド関数とする。入力パターンとして○□△×等の図形をとり、それぞれをN行N列の格子上升目の■、□状態の集合として表現する。これらは N^2 個の入力層ユニットの1, 0状態と対応している。分解能Nとしては、10, 20, 30, 40, 50の5種類を選択した。入力パターン分解能とその認識効率相関を調べるために、各分解能毎にBP法のアルゴリズムに従って学習させたときの、各学習回数T毎(図形1セット学習で1回とする)の誤差二乗和E(出力ニューロン値と教師信号値の差の二乗)の値、各パターンの出力ユニット値、入力層ユニットに対応した荷重逆投影値などを取得した。また、シグモイド関数の傾き及び荷重初期化に関するパラメータr, q、中間層ユニット数を変更した際にも同様のデータを取得した。

本研究ではニューロエミュレータNeuro-07(NEC PC-9801上)⁽⁴⁾を基に、それに必要に応じてソフト的改良を加えることで実験環境を実現した。

3. 結果

図1から図4は、4入力パターン(○□△×)の場合に関する結果の一部である。図1は15回の学習の各誤差二乗和を分解能別に図示したものである。N=30の時、他に比べて認識が速い。図2は15回目における各パターン出力ユニット値を分解能別に示したものである。N=30の場合にどのパターン

Correlation between the resolving power for input data and the efficiency of a pattern recognition by back-propagation learning

Haruhiko NISHIMURA, Nobuki KOYAMA
Hyogo University of Teacher Education

の値もよく揃っているのがわかる。この他、各パターン間の誤認識数についても $N = 30$ において最小になっている。




図1 各分解能における誤差二乗和の経時変化




図2 時刻15における分解能毎の各パターン出力ユニット値

図3、4は、図1の誤差二乗和の経時的加重平均値

$$F = \frac{\sum (E_i \cdot T_i)}{\sum T_i}$$

を導入し、その分解能及びパラメータ r , q 依存性を図示したものである。その結果、 $N = 30$ は最低でパラメータ r , q の変化に対しても安定していることが確認できる。同様の結果は中間層ユニット数の変更に対しても得られている。




図3 加重平均誤差二乗和のシグモイド関数パラメータ依存性(分解能別)




図4 加重平均誤差二乗和の荷重初期化パラメータ依存性(分解能別)

また、荷重逆投影値に関する検討からも以上の傾向を支持する結果が得られている。

4. おわりに

以上の結果から、認識効率に於ける入力パターンデータの分解能依存性は確かに存在し、本実験例の場合 $N = 30$ が極めて安定な形で最適分解能を与えることがわかった。このことはBP法での認識効率に対する入力データ分解能(入力層ユニット数)の影響力の大きさを示すものであると考えられる。このことは定性的には、ハミング距離の増大による認識効率の上昇 $\sim O(N)$ と学習アルゴリズムへの負荷による認識効率の下降 $\sim O(N^2)$ という両者の寄与によって説明できると期待される。今後、入力パターンの種類や個数の変更(イメージスキャナデータ等)による更なる実験を行うとともに、ネットワークの学習効率を最大にする最適構造(最適分解能)の生成アルゴリズムについても考察してゆきたい。

参考文献

- [1] Rumelhart, D. E., Hinton, G. E. and Williams, R., Learning Representations by Back Propagating Errors, Nature, 323, 9(1986)533-536.
- [2] Rumelhart, D. E., McClelland, J. L. and the PDP Research Group, Parallel Distributed Processing, Vol.1, MIT Press (1986).
- [3] Hecht-Nielsen, R., Neurocomputing, Addison Wesley (1990).
- [4] Neuro-07 ユーザーズマニュアル, 日本電気インフォメーションテクノロジー(株)(1990).