

ディジタル型 BP によるベクトル量子化

A Study of the Vector Quantization by the Digital Back Propagation

生駒 史† 丸山 勇介† 長沼 秀典† 大堀 隆文‡
Fumito Ikoma Yusuke Maruyama Hidenori Naganuma Takahumi Oohori

1. はじめに

3層ニューラルネットに対して恒等写像学習を適用した場合、入力データをクラスタリングし、ベクトル空間を有限個の部分空間に分割して、各部分空間を1個のベクトル値で代表するベクトル量子化が実現できる。ここで、中間層に2値出力素子を持つ3層ニューラルネットを用いることができれば、入力-中間層で符号化され、中間-出力層ではその符号から復号されるベクトル量子化器が実現できると考えられる。このようなネットワークの学習法として、渡辺らは揺らぎ駆動学習法を提案し、ベクトル量子化が可能であることを示した[1]。

一方、著者らは、すべての素子を2値出力素子としたネットワークの学習法であるディジタル型BPを提案しており、論理課題や文字認識などに対して効果的であることがわかっている[2]。

本論文では、中間層のみに2値出力素子を持つネットワークに対してディジタル型BPを適用し、ベクトル量子化を実現できることを実験により検証する。数値実験の結果、学習係数を適切に調節することによって、効果的なベクトル量子化を実現できた。

2. ディジタル型BP

ディジタル型BPは、中間層の出力関数にステップ関数を用いたディジタル型ネットワークに対して、出力層の誤差を減少させるように中間層にも教師信号を与えるので、下層の結合係数の修正も可能となる。ディジタル型BPにおける上層の結合係数の修正は式(1)、下層の結合係数修正は中間層教師信号 $T_j^{(p)}$ を与えることにより可能であり、上層と同様に式(2)を用いてデルタ則により修正することができる。

$$W_{kj} = W_{kj} - \alpha (O_k^{(p)} - T_k^{(p)}) O_j^{(p)} \quad (1)$$

$$W_{ji} = W_{ji} - \beta (O_j^{(p)} - T_j^{(p)}) O_i^{(p)} \quad (2)$$

ここで $\alpha, \beta (> 0)$ は学習係数であり、 $O_j^{(p)}, O_i^{(p)}$ は第 p パターンの中間層、入力層の出力を表す。

中間層教師信号 $T_j^{(p)}$ は、上層の誤差を減少させるように式(3)の教師決定因子 $S_j^{(p)}$ の符号が正ならば0、負ならば1、0ならば $O_j^{(p)}$ を $T_j^{(p)}$ にセットする。

$$S_j^{(p)} = \sum_k (O_k^{(p)} - T_k^{(p)}) W_{kj}^{(p)} \quad (3)$$

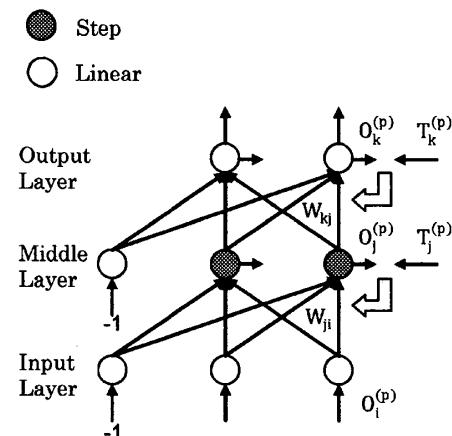


図1 ディジタル型ネットワークの構成図

3. ディジタル型BPによるベクトル量子化

ベクトル量子化は、画像や音声認識、構造パターンの認識などに用いられ、主に情報量の削減などに用いられる。ニューラルネットにおいてはもちろんのこと、他の分野においても、研究を重ねる意義は大きい。

すべての層にディジタル素子を適用した3層ニューラルネットワークに対して恒等写像を学習させた場合、中間層では符号化され、情報の効果的な圧縮が行われている[3]。したがって、入出力層に線形素子、中間層にディジタル素子を配したネットワーク(図1)に対して恒等写像課題を学習させることで、連続値に対してベクトル量子化が可能であると考えられる。

本論文では、2次元平面上に配置した16個のサンプル点に対して恒等写像学習を行い、ディジタル型BPのベクトル量子化特性を検証する。

4. シミュレーション

中間層素子数および学習係数が符号化にどのように影響するのかを見るため、中間層素子数と学習係数を変化させ、恒等写像の学習を行った。

まず、中間層素子数を3, 4, 5と変化させ、出力点の個数(出力パターンと呼ぶ)の変化をみた。実験条件は、学習回数を1500回、上層学習係数 α を0.1、下層学習係数 β を上層の2乗($\beta = \alpha^2$)とした。

学習の過程で出現した、中間層の出力パターン数の推移を図2に示す。

中間層素子数が3の場合(図2(a))、学習がある程度進めば、出力パターン数は一定となる。しかし、理想的なパターン数である4個にはならなかった。中間層素子数が4の場合(図2(b))、出力パターンが4個で一定となり、最も理想的であるといえる。中間層素子数が5(図2(c))の場合、4~6個で振動し、学習回数を延ばしても収束しなかった。

次に、中間層素子数を4に固定し、学習係数を変化させたときの出力パターン数を図3に示す。学習係数は1.0、

† 北海道工業大学大学院工学研究科電気工学専攻

‡ 北海道工業大学工学部情報デザイン学科

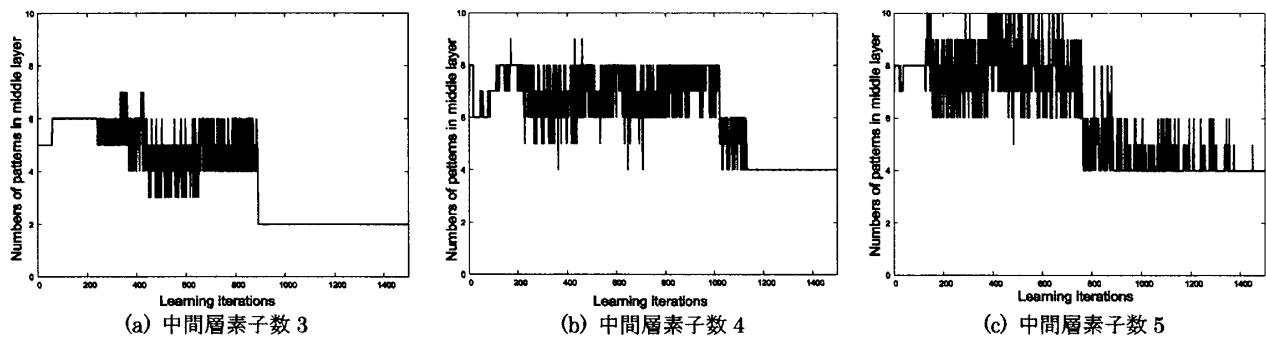


図2 中間層素子数を変化させたときの学習回数ごとの出力パターン数の推移

$0.1, 0.01$ を用い、 $\beta = \alpha^2$ としている

α が 1.0 の場合、出力パターンは 1 個で収束し、誤差は発散してしまった。 α が 0.1 の場合、最も良い結果が得られ、 α が 0.01 の場合では、逆に中間層での出力パターンが変化せず、学習が進まなかった。

以上の結果より、符号化においては、中間層素子数は 4、学習係数は 0.1 程度が良い結果を得られることがわかった。

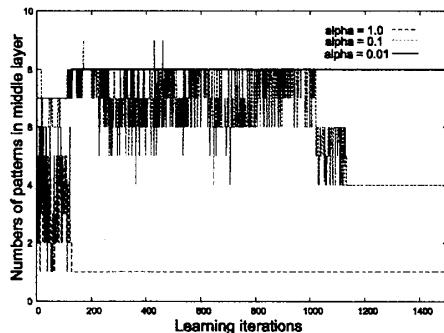


図3 学習係数を変化させたときの学習回数ごとの出力パターンの推移

5. 学習係数の調整による改良型ディジタル BP

符号化においては、学習によって理想的なパターン数(4個)を出力するようになったが、各領域を表す中間層出力パターンが振動し、図 4(a)のように復号化がうまくできなかつた。4 章の結果より、学習係数が小さい場合には中間層での出力パターンが変化しない傾向にあり、下層の学習係数を徐々に減少させることで、学習初期では符号化を、学習終盤では出力パターンを固定し、復号化を効率よく学習できると考えた。

本実験では、下層学習係数を、学習回数ごとの誤差を前回の誤差と比較して、許容誤差($\varepsilon = 0.01$)以下であった場合、0.01 倍するという方法で減少させた。上層学習係数を 0.1 で固定とし、下層学習係数の初期値は 0.1 とした。その他の条件は前実験と同じである。

中間層素子数を 4 とし、結合係数の初期値を乱数系列 10 種で初期化して実験した結果、理想的な結果(図 4(b))となったのは 30%、出力パターンが多かったのは 50%、出力パターンが少なかつたのは 10%、失敗したのが 10% であった。

理想的なベクトル量化に成功した場合の、学習回数ごとの誤差合計とパターン数の推移を図 5 に示す。

図 5 より、学習回数が 200 回ほどでパターン数は 4 個で一定となり、理想的な符号化ができていることがわかる。また、学習回数 400 回を超えたあたりから、誤差も一定値となり、ベクトル量化が実現できたといえる。

今後の課題としては、さらに効果的なスケジューリングや、汎化実験などが考えられる。

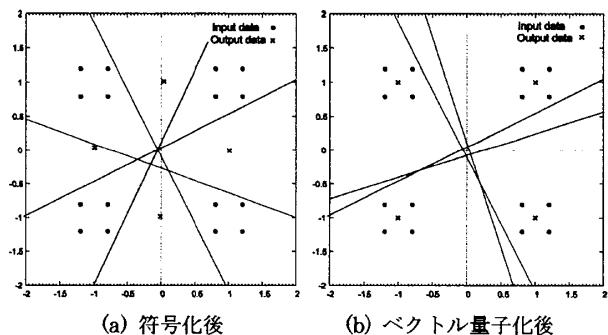
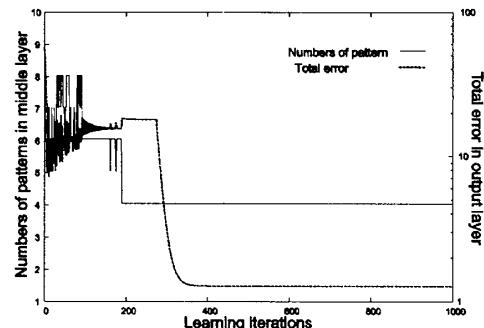
図4 符号化後およびベクトル量化後の出力点
(図中の直線は中間層出力パターンの境界線を示す)

図5 学習回数ごとの誤差合計とパターン数の推移

参考文献

- [1] 渡辺 他, “巡回神経回路網のための揺らぎ駆動学習,” 電子情報通信学会論文誌, D-II, Vol.79, No.5, pp.1247-1256(1997-05)
- [2] T. Oohori, et. al, “A New Backpropagation Learning Algorithm for Layered Neural Networks with Nondifferentiable Units,” Neural Computation Vol.19, No.5, pp.1422-1435(2007-5)
- [3] 丸山 他, “補助ネットワークを用いたディジタル型 BP による恒等写像学習,” 電子情報通信学会論文誌, D-II, 掲載予定