

バックプロパゲーション法における学習性能の 入力パターン分解能依存性

西 村 治 彦[†] 小 山 宣 樹[†]

階層型ニューラルネットワークのバックプロパゲーション法におけるネットワーク構造と学習則に関するパラメータの決定方法は、具体的な応用に際して重要な問題として注目されている。これまでの研究では、ネットワークと外界の接点である入出力層部分は固定し、専ら中間層数、中間層ユニット数、学習係数、ユニットの入出力特性などの内部パラメータの影響やそれらの間の依存関係ばかりが議論されてきた。しかし、学習対象のパターンを2値化された画像データとして処理する場合、そのときの分解能（解像度）に応じて学習パターン間のハミング距離とともに入力層ユニット数が変化することになる。このような変化がネットワークの学習性能に与える影響を調べるために、我々は、ネットワークの上記内部パラメータを固定し、入力パターンの分解能のみを変化させて学習実験を行った。その結果の分析から最良の学習効率を与える分解能の存在が明らかになった。そして、そのような最適分解能が現れる根拠とそのメカニズムについても考察を加えた。

Influence of Input Pattern Resolution on Learning Performance of the Back-Propagation Method

HARUHIKO NISHIMURA[†] and NOBUKI KOYAMA[†]

When the learning method is practically applied to the back-propagation network, selection of the parameters becomes important. The existing researches have been concentrated on how to set the inner parameters such as the number of hidden layers and units, the value of learning coefficient, and the input-output characteristics of units. Then, with regard to input and output layers which contact directly with external signals, the degrees of freedom of their units are almost left fixed. However, the number of input units is usually changed according to the input resolution to process the training patterns as binarized images. That is, modulation of Hamming distances between patterns leads to alteration of the number of input units. To examine this influence on learning performance, we experiment on various input pattern resolutions under the condition of leaving the above inner parameters fixed. As a result it is shown that there exists the optimal resolution which provides a superior efficiency of learning process. We also consider the ground and the mechanism of this occurrence.

1. はじめに

階層型ニューラルネットワークにおけるバックプロパゲーション(BP)法学習則^{1),2)}は、文字認識、音声認識、画像処理など、これまで様々な分野に適用されてきたが、その中で幾つかの難点も指摘され、その改善策が研究されている³⁾⁻⁵⁾。特に、ネットワークの構造と学習則に関する種々のパラメータをどのように決定すべきかは、具体的な応用に際して重要な問題であり、中間層数、中間層のユニット数、学習係数、結合荷重の初期値、ユニットの入出力特性などの最適化について注目してきた。

ただ、これまでの研究に共通していることは、上記パラメータの影響やパラメータ間の依存関係を議論するとき入出力層のユニット数は一定に保たれている点である。つまり、ネットワークと外界の接点である入出力部分は固定し、専ら内部パラメータの影響のみを調べてきたわけである。しかし、学習対象のパターンを画像として扱う場合には、分解能（解像度）に応じて入力層のユニット数が変化し、同一学習対象でもそのときの分解能の設定によってネットワークの構造自体が違ったものになる。このような変化は当然、ネットワークの学習性能に影響を与えることになる。画像2値化を単なる前処理として切り離して考えるならば、入力パターンの分解能を上げることは各パターン間の違いを際立たせる（ハミング距離の増大）というだけのことであるが、ネットワーク全体で捉えれば系

[†] 兵庫教育大学情報科学研究所
Department of Information Science, Hyogo
University of Teacher Education

の自由度の増加につながる。果たして、入力パターン分解能の変化に伴う入力層ユニット数変更はネットワークの学習過程にどのような影響を及ぼすのか。このことを実験的に検証した例⁶⁾は我々の知る限りでは他に報告されておらず、これまでの内部パラメータに関する研究と同様、その検討が必要であると考える。

このような観点から本論文では、BP 法学習過程における効率評価尺度として学習効率評価指數⁷⁾を導入し、これを用いて実験的に学習効率の入力パターン分解能依存性について調べることにする。さらに最良の学習効率を与える分解能の存在とその出現メカニズムについても考察を加える。

以下、第 2 章では、BP 法学習則について簡単に触れるとともに、学習過程全体の効率（学習曲線の経時的ふるまいの違い）を数値的に記述する学習効率評価指數を新たに導入する。第 3 章では、入力パターンの分解能別にパターン学習実験を行い、それぞれの結果から学習効率の入力パターン分解能依存性について明らかにする。さらに第 4 章では、最適分解能出現のメカニズムについて考えるとともに、その定式化を試みる。最後に本論文での結論と今後の課題について第 5 章で述べる。

2. BP 法学習過程とその効率評価尺度

階層型ニューラルネットワークは入力層、出力層およびいくつかの中間層からなり、入力から出力方向への層間結合はあるが層内結合はない。中間層、出力層の各ユニットの入出力関係は、

$$y_i = f\left(\sum_j w_{ij} x_j\right) \quad (1)$$

で与えられる。ここで w_{ij} はユニット j から次層のユニット i への結合荷重、 $\{x_j\}$ はユニット j からユニット i への入力値である。しきい値はバイアスユニット ($j=0$) からの入力 ($x_0=1$) による結合荷重 w_{i0} の効果として解釈できる。出力関数 f としては有界で単調増加のシグモイド関数

$$f(s) = \frac{1}{2} \left(1 + \tanh\left(\frac{s}{\kappa}\right) \right) \quad (2)$$

をとる。 κ はシグモイド関数の傾き係数で、 $\kappa \rightarrow 0$ の極限で $f(s)$ は階段関数に一致する。

ネットワークの入力層にパターン p を提示した際の出力層ユニット i の出力を o_{pi} 、教師データによる目標出力を d_{pi} とするとき、誤差関数は、

$$E = \sum_p E^{(p)} = \sum_p \sum_i (o_{pi} - d_{pi})^2 \quad (3)$$

で定義される。BP 法学習則はこの E を最小とする結合荷重およびしきい値を最急降下法を用いて逐次近似的修正によって求めてゆこうとするものである。その修正量は、

$$\Delta w_{ij} = \eta \delta_i x_j \quad (4)$$

によって与えられる。ここで、 η は学習係数である。 δ_i は、ユニット i が出力層にあるか、中間層にあるかで異なる。今、ユニット i への入力の総和を S_i とすると、出力層の場合には、

$$\delta_i \equiv \delta_{2i} = (d_i - o_i) f'(S_i) \quad (5)$$

中間層の場合には、

$$\delta_i \equiv \delta_{1i} = \left(\sum_l \delta_{2l} w_{il} \right) f'(S_i) \quad (6)$$

となる。ただし、 $f'(s)$ は関数 f の微分である。

誤差関数 E の値は、ネットワークが正しい答にどのくらい近づいているかを表す学習の定量的尺度としての意味を持つ。学習回数に対する E 値のふるまい全体を学習曲線と呼ぶ。学習曲線は学習が収束するまでの履歴を記述するものである。この学習曲線の違いを数値化することでネットワーク全体の学習効率の定量的評価が可能になる。

そのため我々は先に、学習過程における効率評価尺度として L 値なる量を提案し、その性質と有効性について検討した⁷⁾。 L 値は以下のように定義される。まず、 E 値の学習回数に対する経時加重平均

$$F_\alpha = \frac{\sum_{t=1}^f E_t \sqrt[t]{t}}{\sum_{t=1}^f \sqrt[t]{t}} \quad (7)$$

と E 値の変化率の経時加重平均

$$G_\beta = \frac{\sum_{t=1}^f \{\log_{10}(E_{t-1}/E_t)\} (1/\sqrt[t]{t})}{\sum_{t=1}^f (1/\sqrt[t]{t})} \quad (8)$$

を導入する。ここで、 α, β は F, G それぞれの累乗根のパラメータであり、 t は学習時刻（学習の進行回数）である。この両者の比

$$L = \frac{F}{G} \quad (9)$$

が L である。

一般に効率の良い学習過程とは、 t の早い時期に E_t が学習ごとに大きく低下し、その後もゆるやかながら順調に減少する過程をさす。 F_α, G_β で言えば、 F_α が小さく G_β が大きいほどこの傾向が強いことになる。つまり、 L 値が小さいほど学習の際の効率は良い

ということになる。このことは、アルファベット 26 文字の学習実験を通して実際に確認されている⁷⁾。また、そこでは学習負荷との相関や学習後認識時におけるノイズ影響との関係についても調べられている。我々はこの結果に基づき、本研究での学習性能の評価指標として L 値を採用することにする。

3. 分解能別パターン学習実験と学習効率

3.1 分解能別パターンデータ作成

学習効率の入力パターン分解能依存性を調べるために、まず、入力パターンの分解能について明確にしておかなければならない。一般に、分解能（あるいは解像度）とは画像がどの程度、空間的に細かな情報を含むかを示す指標を言う。ニューラルネットワークの場合、入力パターンデータとの接点である入力層ユニット数の多少が分解能の大小と結びつくことになる。つまり、入力層ユニット (N^2 個) を 2 次元配列 (N 行 N 列) で考えたとき、 N が大きくなるほど、同一対象から空間的により細かな情報を得ることができるのである。したがって、本研究ではこの N のことを分解能と呼ぶことにする。

次に、各分解能における入力パターンデータの具体的な作成法を述べる。使用する入力パターンの各图形を N 行 N 列の 2 次元配列上で描き、图形の線が通過する格子に対応する入力ユニット値を 1、それ以外のユニット値を 0 とする。图形の輪郭線自体の幅は、ここで考える分解能（解像度）の範囲では見えてこない程度の細さを想定した。図 1 に、○□△× の 4 種類の图形に対する $N=10, 30, 50$ の 3 つの場合のパターンデータを示してある。多数または複雑な图形を対象とする場合、イメージスキャナー等を利用して分解能別パターンデータを作成することも可能である。しかし、そのときには、ノイズの発生やスキャン時の光量依存性の問題があるので、注意が必要である。

3.2 BP 法基本設定

分解能別入力パターンは、上述のように、それぞれの图形を N 行 N 列の格子上升目の■、□状態の集合として表現し、それを N^2 個の入力層ユニットの 1, 0 状態に対応させて構成した。また、目標出力である教師パターンは、各图形種に対応する 1 箇所のみが 1 で他がすべて 0 である直交パターンとした。このとき、出力層のユニット数は学習パターン数 (N_p) 分必要となる。

ネットワークは 3 層構造とし、データ取得に際して

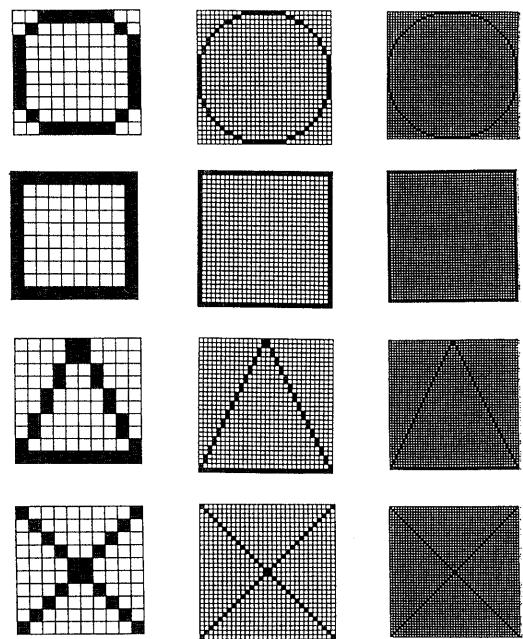


図 1 学習実験用分解能別入力パターンデータ例
(分解能 $N=10, 30, 50$ の場合)

Fig. 1 Examples of training patterns divided into pixels according to each resolution N . ($N=10, 30, 50$ cases.)

は、中間層のユニット数は 5、シグモイド関数の傾き係数は $\kappa=0.75$ 、学習係数は $\eta=1$ とした。結合荷重としきい値の初期値は一様乱数 ($\leq |0.2|$) で与えることとした。以上の設定の下、1 パターン提示ごとに結合荷重としきい値を修正する逐次修正法によって 100 回 ($f=100$) 学習を実行した。ただし、ここでは N_p 個 1 巡で学習 1 回と呼んでおり、結合荷重としきい値の修正回数でいえば $100 N_p$ 回ということになる。

3.3 学習効率のパターン分解能依存性

さて、分解能ごとに、結合荷重としきい値の初期値が異なる 100 例ずつについて(9)式の L 値を求め、分解能別にどのような違いがあるかを調べることにする。(7), (8)式の F_α , G_β の累乗根パラメータとしては、ここでは $\alpha=2$, $\beta=3$ を選択した。図 2 は学習実験で得られた学習曲線の中から適当な 4 例を図示したものである。図中の(1)～(4)の順に、その L 値は(1)1.08, (2)2.25, (3)4.50, (4)9.44 となり、各学習過程に見られる学習効率の違いの定量的評価尺度として機能しているのがわかる。ところで 100 例の中には、収束性が悪く、はずれ値としての L 値を与える学習例がいくつか出現し、そのため L 値の分布

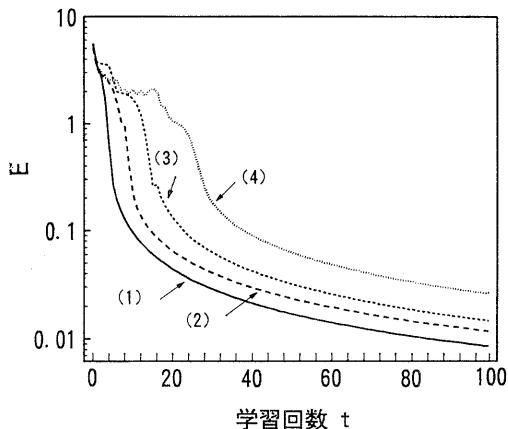


図 2 パターン学習実験における学習曲線例 (それぞれの L 値は (1)1.08, (2)2.25, (3)4.50, (4)9.44)
Fig. 2 Learning behaviors for typical 4 examples.
(1) $L=1.08$, (2)2.25, (3)4.50, (4)9.44.)

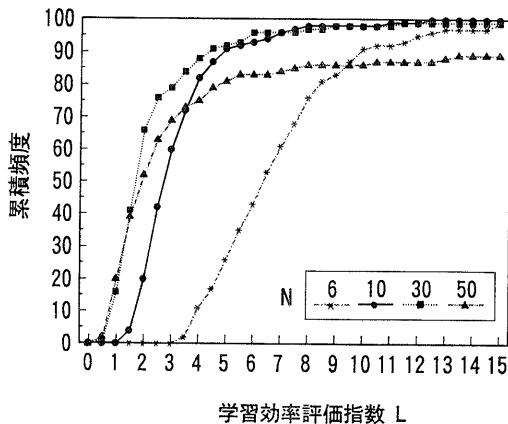


図 3 100 学習例の L 値に関する累積頻度分布 (4 パターン学習, 分解能 $N=6, 10, 30, 50$ の場合)
Fig. 3 Cumulative distributions of L value for 100 trials in the case of four learning patterns. (Resolution $N=6, 10, 30, 50$ cases.)

は正規分布にならず、分解能によってもその形状は多少違ったものとなると考えられる。そこで、はずれ値や分布のゆがみに対してロバストネス（頑健性）がない平均値はやめ、100 例に対する L 値の累積頻度分布によって評価を行うこととする。

図 3 は、4 種類 ($\circ \square \triangle \times$) のパターン学習実験の結果を分解能 $N=6, 10, 30, 50$ の場合について図示したものである。このグラフから分かるように、 $N=6, 10, 50$ の場合に比べて、 $N=30$ の場合の L 値は低域により多く分布している。また、 $N=50$ の場合に

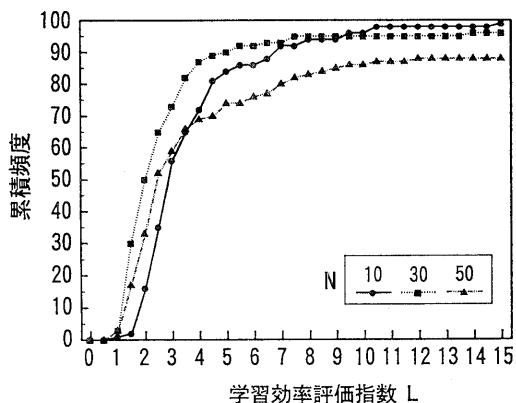


図 4 100 学習例の L 値に関する累積頻度分布 (5 パターン学習, 分解能 $N=10, 30, 50$ の場合)
Fig. 4 Cumulative distributions of L value for 100 trials in the case of five learning patterns. (Resolution $N=10, 30, 50$ cases.)

は、累積頻度が 85 あたりで頭打ちとなり、学習効率のかなり悪い例が他に比べて多いことがわかる。この傾向は、入力パターンの種類や個数の若干の変更に対しても確認されている。例えば、図 4 は入力パターンを 5 種類 ($\circ \square \triangle \times +$) にしたときの L 値に関する累積頻度分布であるが、この場合も、 $N=30$ のときに学習効率の良い例が多く存在する結果になっている。

以上の実験結果から、ニューラルネットワークの学習効率は入力パターン分解能に依存し、しかも、学習効率にとって最適な分解能（ここでは分解能 $N=30$ ）の存在が統計的傾向として確認された。

4. 最適分解能出現の根拠

4.1 学習時入力層ユニットの役割

第 2 章で述べたように、 j 番目の入力層ユニットと i 番目の中間層ユニットを結ぶ結合荷重の修正量は

$$\Delta w_{ij} = \eta \delta_{1j} x_i \quad (10)$$

で与えられる。この式から $x_j=0$ のとき、 $\Delta w_{ij}=0$ となるのは明らかである。今、 x_j は j 番目の入力層ユニット値で、入力パターンに応じて 0 または 1 の値をとるので、学習させるパターンごとに、修正される結合荷重と修正されない結合荷重が存在することになる。我々は、この前者を与える入力層ユニット ($x=1$) のことを荷重修正寄与ユニット、また、後者につながる入力層ユニット ($x=0$) のことを荷重修正傍観ユニットと呼ぶことにする。さらに、ある入力パターンの荷重修正寄与ユニットの中で、同時に他の入力パ

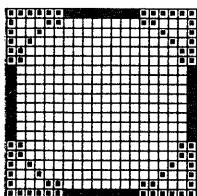
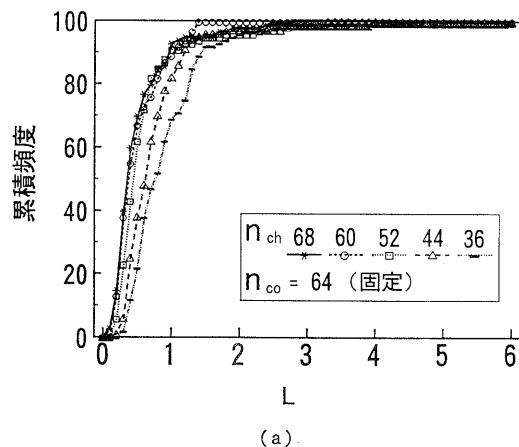


図 5 2パターン (\circ と \square) 間での入力層ユニットの分類
Fig. 5 Classification of input units between two patterns, \circ and \square .

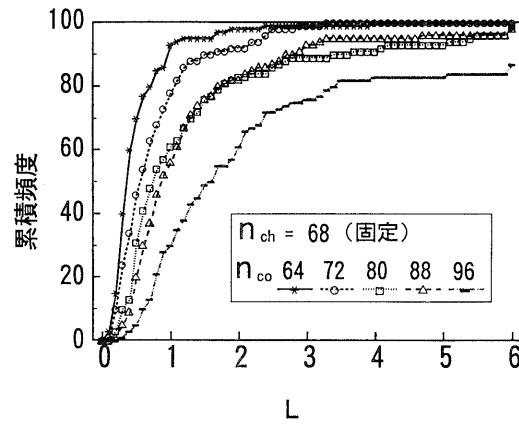
ターンの荷重修正寄与ユニットでもあるものをパターン共通ユニット、そうでないものをパターン固有ユニットと類別することにする。例えば、 \circ と \square の2種類のパターン ($N=20$) の間では、入力層ユニットの分類は図5のようになる。この場合、両者の固有ユニット数は $n_{ch}=68$ 、共通ユニット数は $n_{co}=64$ である。

次に、このように分類された入力層ユニット群の役割について検討する。パターン固有ユニットは、そのパターンのみで $x=1$ であるから、荷重修正において他のパターンと競合しあうことではなく、そのパターンの特徴抽出を促進することになる。したがって、パターン固有ユニットが荷重修正寄与ユニットの中に占める割合が多いほど、学習効率は良くなると考えられる。それとは逆に、パターン共通ユニットは、異なるパターン間に共通して $x=1$ であるから、荷重修正においてパターン間で競合しあうことになる。したがって、パターン共通ユニットが荷重修正寄与ユニットの中に占める割合が多いほど、学習効率は悪くなると考えられる。

このことを、 \circ と \square 2種類のパターン学習実験を通して具体的に確かめてみる。入力パターンデータの分解能は $N=20$ とし、その他の BP 法基本設定は第3章の場合と同様にした。固有ユニット、共通ユニットそれぞれの学習効率への影響力を見るために、共通ユニット数を固定 ($n_{co}=64$) して固有ユニット数のみを変更したパターン対を 5 種類、逆に固有ユニット数を固定 ($n_{ch}=68$) して共通ユニット数のみを変更したパターン対を 5 種類という計 10 種類の学習パターンセットを用意した。それぞれの場合に、結合荷重としきい値の初期値が異なる 100 例について L 値を求め、その累積頻度分布を表したのが図6である。図6(a)から、固有ユニット数の減少 ($n_{ch}=68$ から 8 個ずつ) に伴い、分布が L 値の高域へと推移し、統計的傾向として L 値が大幅に悪くなっていく様子が確認できる。このことから、パターン共通ユニットが多いほど学習効率が悪いことがわかる。また、両者のグラフを比べると、同数のユニット変化が L 値の累積頻度分



(a)



(b)

図 6 2パターン学習 (各々 100 例) における L 値の累積頻度分布。(a)パターン固有ユニット数 n_{ch} の違いによる影響。(b)パターン共通ユニット数 n_{co} の違いによる影響。

Fig. 6 Cumulative distributions of L value for 100 trials in the case of two learning patterns. (n_{ch} : the number of characteristic units, n_{co} : the number of common units.)
(a) Distributions obtained by changing n_{ch} with fixed n_{co} . (b) Distributions obtained by changing n_{co} with fixed n_{ch} .

できる。このことから、パターン固有ユニットが多いほど学習効率が良いことがわかる。一方、図6(b)からは、共通ユニットの増加 ($n_{co}=64$ から 8 個ずつ) に伴い、分布が L 値の高域へと推移し、統計的傾向として L 値が大幅に悪くなっていく様子が確認できる。このことから、パターン共通ユニットが多いほど学習効率が悪いことがわかる。また、両者のグラフを比べると、同数のユニット変化が L 値の累積頻度分

布に与える影響は、図6(b)の共通ユニットの場合の方が、図6(a)の固有ユニットの場合よりかなり大きくなっている。これは、学習効率への影響という点では、共通ユニット数の変化の方が固有ユニット数の変化よりも深刻であることを示すものと解釈できる。

4.2 考 察

さて、前節で明らかになった入力層ユニットの役割に基づいて、学習効率を最も良くする分解能 N_{opt} の出現メカニズムについて考えてみると、定性的には次のようになる。

- ①入力パターンデータに対する分解能 N を上げると、入力層の荷重修正寄与ユニット数が増加する。
 - ②この荷重修正寄与ユニット数の増加は、パターン固有ユニット数 n_{ch} とパターン共通ユニット数 n_{co} の両方の増加を引き起す。
 - ③このとき、 n_{ch} の増加は、個々のパターンの特徴抽出を促進する結合荷重修正を増やし、学習効率の上昇 (L 値→小) を促す。
 - ④一方、 n_{co} の増加は、個々の特徴抽出を阻害する結合荷重修正を増やし、学習効率の下降 (L 値→大) を促す。
 - ⑤③と④が互いに競合する結果、そのときの分解能に応じた学習効率が決まる。
- 先の○と□の2パターン学習の場合を例に、①～⑤の定式化を試みることにする。まず、各分解能に対する固有ユニット数と共通ユニット数をグラフ上にプロットしたのが図7である。これより、分解能と各ユニット数はほぼ比例しており、その関係は

$$n_{ch} = \alpha N + b, \quad (11)$$

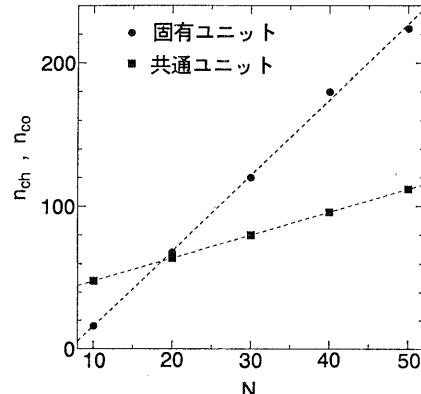


図7 2パターン(○と□)間の固有および共通ユニット数 n_{ch} , n_{co} と分解能 N の関係

Fig. 7 Relation between the number of characteristic (common) units n_{ch} (n_{co}) and the resolution N .

$$n_{co} = cN + d \quad (12)$$

となる。ただし、 a, b, c, d は定数で、今の場合、 $a > c > 0, b < d$ である。次に、上述の③と④における学習効率と固有、共通ユニット数との関係を、

$$L \propto L_1 e^{-\lambda_1 n_{ch}} + L_2 e^{\lambda_2 n_{co}} \quad (13)$$

と表現することにする。ただし、ここでは、関数形として指数関数を仮定した。 $L_1, L_2, \lambda_1, \lambda_2$ は正の定数である。(13)式に(11)式と(12)式を代入することにより、分解能 N の関数として L の式

$$L = L_1 e^{-\lambda_1 (\alpha N + b)} + L_2 e^{\lambda_2 (cN + d)} \quad (14)$$

を得る。この L の N での2階微分 L'' は、常に $L'' > 0$ であるから、 L は N に対して最小値をもつことがわかる。最小値を与える N は、 $L' = 0$ を解くことにより、

$$N_{opt} = \frac{1}{\lambda_1 a + \lambda_2 c} \left(\ln \left(\frac{\lambda_1 a L_1}{\lambda_2 c L_2} \right) - (\lambda_1 b + \lambda_2 d) \right) \quad (15)$$

で与えられる。ここで、 \ln は自然対数である。

以上、学習効率を最良にする最適分解能 N_{opt} の出現の根拠とメカニズムについて述べてきた。ただし、上記の2パターンの具体例は最も簡単な場合の例に過ぎないことを注意しておく。一般に学習パターン数が p の場合には、パターン共通ユニットは、2パターン間で共通、3パターン間で共通、……、 p パターン間で共通という具合に共通度に応じた ($p-1$) 種類が発生する。この場合には、 L を与える式は高次・複雑化し、(14)式のような定式化は困難である。

5. おわりに

本論文では、結果の信頼性と一般性を失わないために、結合荷重としきい値の初期値について100種類用意し、統計的な立場から議論を進めてきた。分解能依存性実験では、学習パターンとして○□△×、○□△×+の場合の結果しか示さなかったが、パターン数を6種類にした場合やパターン内容に変更を加えた場合にも、最適分解能出現という同様の結果を得ている。○□△×パターン間に共通部分を増やす形でパターン内容変更を行った場合、最適分解能は $N=30$ から $N=20$ へとシフトする傾向が見られた。これは、パターン共通ユニットの増加により固有ユニットとの競合バランスが動いたことによるもので、4.2節の考察で述べたメカニズムからも予想できる結果である。また、学習回数を $f=100$ から $f=200$ へ増やした場合の実験でも、 L 値が全体的に小さくなるだけで、分解能依存性の結果に変わりはなかった。

本論文では、中間層のユニット数が5の場合の結果のみを述べたが、他の値(7, 10, 13)の場合についても同様の実験を行っている。その結果からは、中間層ユニット数の増加はどの分解能に対してもほぼ一様にその学習効率を上昇させる(L 値を小さくする)。それとともに、最適分解能を $N=30$ から更に大きい方へ徐々にシフトさせていく傾向が見られた。これは、中間層ユニット数の増加が結合荷重全体の自由度を大きくし、パターン学習における特徴抽出の際の競合緩和を促すためであろうと考えられる。

学習パターン数、分解能および中間層ユニット数を大幅に増やして実験を行うことは、本研究におけるこれまでの結論をさらに確かなものにする上でも興味あるところである。しかし、計算機上のメモリと処理時間への負担を考慮すると、現時点ではなかなか困難なものがあり、実験システム環境の工夫も含めて今後の課題の1つである。

最適分解能出現のメカニズムについては、2パターン学習の場合にその具体的定式化を試みたが、この一般化は難しく最適分解能を解析的に求めることはできない。したがって今後の応用を考えると、遺伝的アルゴリズム^⑧等を取り入れた自己適応的な最適分解能探索アルゴリズムの構築が必要であると思われる。

参考文献

- 1) Rumelhart, D. E., Hinton, G. E. and Williams, R. J.: Learning Representations by Back-Propagating Errors, *Nature*, Vol. 323, No. 9, pp. 533-536 (1986).
- 2) Rumelhart, D. E., McClelland, J. L. and the PDP Research Group: *Parallel Distributed Processing*, Vol. 1, MIT Press (1986).
- 3) 倉田耕治, 麻生英樹: 神経回路網の理論的研究における最近の動向, 電子情報通信学会論文誌, Vol. J73-D-II, No. 8, pp. 1103-1110 (1990).
- 4) 喜多 一: ニューラルネットワークの汎化能力, システム/制御/情報, Vol. 36, No. 10, pp. 625-633 (1992).

- 5) 石川真澄: ネットワーク学習アルゴリズムの最近の話題、計測と制御, Vol. 30, No. 4, pp. 285-290 (1991).
- 6) 西村治彦, 小山宣樹: 階層型ニューラルネット学習効率の入力パターン分解能依存性評価、第45回情報処理学会全国大会論文集(2), pp. 321-322 (1992).
- 7) 西村治彦, 小山宣樹: バックプロパゲーション法学習過程における効率評価尺度の検討、情報処理学会論文誌, Vol. 34, No. 9, pp. 1892-1898 (1993).
- 8) Goldberg, D. E.: *Genetic Algorithms in Search, Optimization, and Machine Learning*, Addison-Wesley (1989).

(平成5年3月18日受付)
(平成6年9月6日採録)



西村 治彦 (正会員)

1980年静岡大学理学部物理学科卒業。1985年神戸大学大学院自然科学研究科博士課程修了。1989年広島大学医学部(医療情報学)助手。1990年12月より兵庫教育大学(情報科学)助教授、現在に至る。学術博士。これまでファジー・データベース、ニューラルネットワーク、セルオートマトン、複雑系の科学等の研究に従事。日本神経回路学会、日本物理学会、電子情報通信学会等、各会員。



小山 宣樹 (正会員)

1953年生。1977年武蔵工業大学工学部経営工学科卒業。現在、和歌山県立田辺工業高等学校教諭。1991~1993年兵庫教育大学大学院にて、ニューラルネットワーク等の研究に従事。修士(学校教育学)。日本オペレーションズ・リサーチ学会、日本産業技術教育学会、日本教育工学会等、各会員。