

## 42A-01 高速適応能力と情報集約能力を有する神経回路モデル

田川尊浩<sup>†</sup> 山内康一郎<sup>†</sup> 石井直宏<sup>†</sup> 伊藤幸夫<sup>†</sup>  
<sup>†</sup>名古屋工業大学<sup>†</sup> ヤマハ発動機

## 1 はじめに

現実の問題に対して人工神経回路を含むシステムを運用しようとするとき、この神経回路に求められる能力として、新しい学習サンプルが提示されたときに、すでに学習した内容を忘却することなくそれを確実に学習できる能力(高速適応能力)、少数の中間細胞で学習できる能力(情報集約能力)などが挙げられる。しかし、これらは相反する能力である。つまり、高速な適応能力を実現するには、多くの中間細胞を用意する必要があり、逆に、情報を集約するために中間細胞数を減らすと適応速度が遅くなってしまふ。そこで本稿では、これらの相反する能力を両立する神経回路モデル [1] を提案する。

## 2 システムの概要

本研究で提案するシステムは、Fig.1 で示されるように、GRBF 型 [2] の一種である Resource Allocating Network(RAN)[3] を 3 つ組み合わせた構造をしている。これらはそれぞれ

- ・主に認識を担当する Main-Net
- ・Main-Net と望ましい出力との誤差を補完するように高速に学習する F-Net
- ・F-Net の出力を少数の中間細胞で近似する S-Net である。

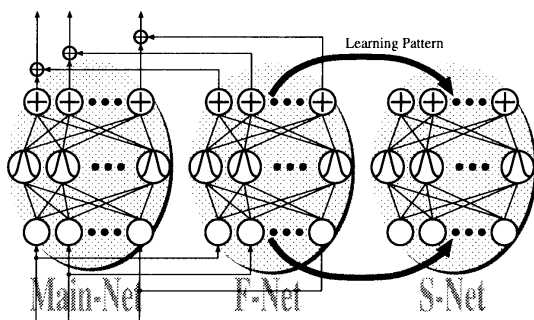


Fig.1 network structure

このシステムの最終出力は、Main-Net の出力  $f^*(x, \theta_M)$  と F-Net の出力  $f^*(x, \theta_F)$  を合わせた出力であり、  

$$f^*(x) = f^*(x, \theta_M) + f^*(x, \theta_F)$$

Combination of Fast and Slow learning networks for fast adaptation and reduction of redundant cells  
 Takahiro Tagawa<sup>†</sup>, Koichiro Yamauchi<sup>†</sup>, Naohiro Ishii<sup>†</sup>, Sachio Itoh<sup>†</sup>,  
<sup>†</sup>Nagoya Institute of Technology, <sup>†</sup>YAMAHA MOTOR

である。提案システムでは、高速適応能力と情報集約能力という相反する能力を両立させるため、学習期間を 2 つに分ける。これをここでは、「昼の学習」「夜の学習」と呼ぶことにする。昼の学習期間中は、提示された学習サンプルに対する Main-Net の誤差を吸収するように F-Net が高速に学習する。この高速な学習は、多くの中間細胞を割り付けることで実現する。また、夜の学習期間中は、S-Net が F-Net の出力をより少ない細胞数で近似してその結果を Main-Net に保存する。提案システムはこれらを交互に繰り返す。このように学習期間を 2 つに分けるのは、システム全体の細胞数が増えすぎないようにするためのものである。すなわち、F-Net による速い学習と遅い学習による細胞数削減とを同時並行に行なおうとすると、入力パターン分布が変動する場合には結局 F-Net の細胞数が増え続ける。[4] この場合、本来の目標である情報集約能力を実現できない。そこで定期的に新規パターン学習を打ち切って、冗長な中間細胞数を削減する夜の学習期間を設ける。

## 3 計算機実験

本研究で提案するシステムの能力を確認するため、Fig.2 で表される簡単なガウス関数を用いた関数の近似を行った。一般的に神経回路は学習期間中に入力パターンの分布が変化すると、パターン分布が変化する前に学習した内容を忘却することがある。提案システムでは、このような場合でも忘却を極力防ぐ能力があることも併せて示す。




Fig.2 example of learning pattern

学習パターンは 1 次元入力 1 次元出力の関数を使用する。ただし、 $x$  の領域  $[0, 2]$  における学習パターン

200 個を学習させた後に、 $x$  の領域 [2, 4] における学習パターン 200 個を学習させる。

比較実験として、オリジナルの RAN と F-Net のみのシステムを用いた。二乗誤差および中間細胞数の推移を Fig.3, Fig.4 に示す。

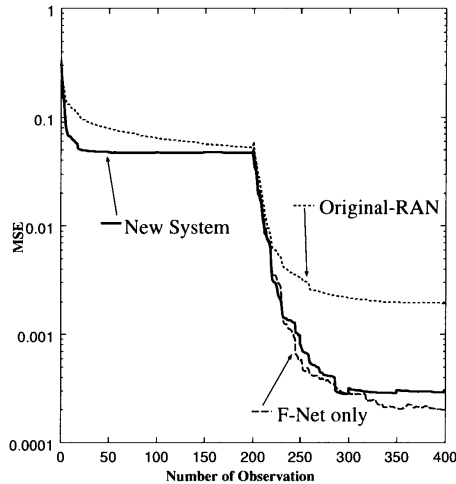


Fig.3 average squared error

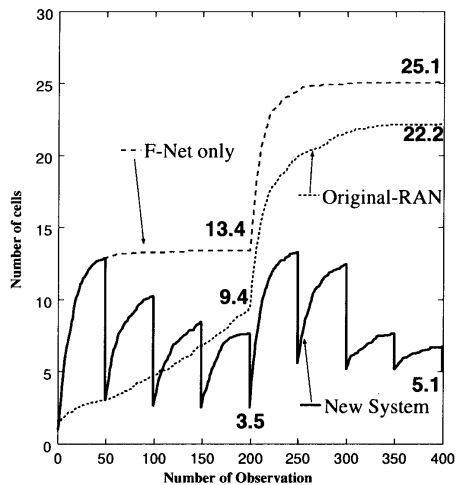


Fig.4 number of hidden unit

Fig.3 より、400 個のパターンを提示した後のオリジナルの RAN の二乗誤差は約 0.002 付近となっている。これは、入力領域が学習期間中に変化するため、変化する前のパターンを忘却しているためである。入力領域が変化した後、変化前の学習で割り付けた細胞のパラメタを更新すると、忘却を起こす原因となる。特にこの忘却は、割り付けられている中間細胞が少ない場合、顕著になる。また、オリジナルの RAN は、学習の初期段階では中間細胞を疎に割り付けるが、学習と進行と共に細胞の割り付け条件を緩和していく。そのため、入力

領域が変化した直後に割り付けられる細胞の数は、学習初期段階に比べて大きく増えることになる。

一方、F-Net のみのシステムは、学習の初期段階から多数の細胞を割り付けて学習するため、適応速度は速い。またそのため、入力領域が変化しても、その影響は一部小数の細胞のみが受けるため、大きな忘却は起こりにくい。

提案システムは、学習初期段階から高速な適応をしつつも、夜の学習によって冗長な細胞数を削減している。(Fig.4 には夜の細胞数は示されていない。提案システムの細胞数の推移が不連続になっているのは夜の学習による細胞数の減少によるものである。) また、更新が必要なパラメタ以外は固定するため、環境が変化した後も大きな忘却は抑制されている。

#### 4 まとめ

本稿では、2つの相反する能力、高速適応能力、情報集約能力を両立する神経回路モデルを提案した。実験の結果、これら2つの相反する能力を有していることが明らかになった。

今後は、S-Net の近似精度の向上と計算時間の短縮、F-Net の学習方法を高精度の追加学習法に置き換えることを検討する必要があると考えられる。

#### 参考文献

- [1] 伊藤幸夫, 山内康一郎, 石井直宏. 高速適応能力と情報集約能力を有する神経回路モデル. 信学技報, NC98-108, 1999.
- [2] Tomaso Poggio, Federico Girosi. Networks for approximation and learning Proc. IEEE on Neural Networks, Vol.78, No.9, pp.1481-1497, 1990.
- [3] John Platt. A Resource-Allocating Network for function Interpolation. Neural Computation 3, pp.213-225, 1991.
- [4] 山内康一郎, 石井直宏. 速い学習と遅い学習を用いた中間細胞数削減法. 信学技報, NC97-60, 1997