

進化ニューラル・ネットワークによる連想記憶実現 Associative Memory in Evolving Neural Networks

神戸大学 自然科学研究科 藤田成隆

E-mail: fujitan@phys02.phys.kobe-u.ac.jp

兵庫教育大学 情報科学 西村治彦

E-mail: HNISHIMU@JPNYITP.BITNET

1. はじめに

連想記憶のモデルとしてのHopfieldモデル[1]は、統計物理学の手法を用いた解析が可能であることで注目され、解析的手法に加えて計算機シミュレーションを用いることで、多くの修正・改良モデルが作られている。これらモデルは、その単純さにもかかわらず興味深い結果を生むのであるが、シナプス間の対称・全結合を基礎としており、実際の生物の脳にみられるものと比較してはなほだ不自然なものである。非対称ウェイトや結合切断による希薄化などの試みも報告されているが、多くはある限られた条件の下での記憶容量の考察にとどまっている。

また上記のモデルにはニューロンの物理的な位置とかニューロン間の距離といった情報が、生物の脳内のネットワーク構成においてその重要な役割が予想されるにもかかわらず、全く含まれてはいない。より自然な、つまり生物学的・発生論的な視点に基づいたモデル構成への試みがあって然るべきではないだろうか。

遺伝的アルゴリズムはこうした方向への可能性として有力なものと考えられよう。階層型ニューラル・ネットワークに遺伝的アルゴリズムを適用したものは多く見られるが[2]、これらは層間の結合様式またはニューロン間のシナプス結合荷重を遺伝子にコーディングし、これに遺伝的アルゴリズムを適用することによるニューラル・ネットワークの性能向上を主な目的としている。

本研究の目的は遺伝的アルゴリズムを相互結合型ニューラル・ネットワークに適用することで連想記憶を考察することにある。生物学的な視点に基づいたモデルの構築にあたり、我々は以下の2点を、ネットワーク形成の際に含まれるべき条件とする。

- ・遺伝子型と表現型とに直接的対応がないこと。
- ・ニューロンの物理的位置・距離を考察対象とすることが可能であること。

これら条件を満たすモデルの実現のために、我々はNolfiらによるモデル[3][4]を参照した。モデルの大枠は以下のようなものである。

- (1) ネットワーク生成情報がコード化された遺伝子型を持つ複数の個体を用意し、
- (2) 生成されたネットワークに対し、適当な学習則によって記銘パターンを学習させ、
- (3) 記銘パターンを想起することがタスクとして各個体に要求されて、

(4) 良い成績を残した個体が選択され、遺伝子型を継承する。ただし継承の際、突然変異が加わる。

(5) ある世代まで(2)~(4)を繰り返す。

2. モデルについて

個体数をMとする。各個体はネットワーク構造を生成するための情報をコーディングした遺伝子型を持つ。遺伝子型はN個のニューロンに対応したN個のブロックに分ける。各ブロックにはニューロンの<Physical Space> (2次元空間=正方形) 上の位置 x , y , <Axon>の方向角 α 、分岐角 θ 、分岐長 d 、シナプス結合のウェイト(<presynaptic> a と <postsynaptic> b) の情報が入る。数値は全て実数で、第0世代においてランダムに与えられる。各ニューロンは正方形中に配位され、ニューロンから<Axon>がFig.1のように伸びて、他ニューロンと結合する。他ニューロンとの結合はAxonが他ニューロンの近傍 r に達したか否かによって決定。




Figure. 1 Axonの成長と分岐過程

学習前の"Bare"な結合荷重はニューロン i からのびたAxonがニューロン j と結合したとき $w_{ij}^0 = a_i b_j$ とし、結合が実現されなかったものに対しては $w_{ij}^0 = 0$ と決める。従って結合荷重は一般に非対称なものとなる。

"Bare"な結合荷重に対し p 個の記録パターン $\{\xi_i^\mu = \pm 1\}$ ($\mu=1, \dots, p$, $i=1, \dots, N$) を用意して、適当な学習則により記録パターンをBareなウェイトに埋め込んでいく：

$$w_{ij}^{New} = w_{ij}^{Old} + \delta w_{ij}.$$

こうして学習によって"Dressed"されたウェイト w_{ij} を持つ個体に「想起タスク」を課す。ニューロン初期状態としてランダム・ノイズが入った記録パターンを与え、発展方程式 $s_i(t+1) = f(\sum_{j=1}^N w_{ij} s_j(t))$, $f(x) = \tanh(x/2\epsilon)$ に基づいた時間発展をさせる。そして適当な時刻でニューロン状態と記憶パターンとの重なり度 $m^\mu = \frac{1}{N} \sum_{i=1}^N \xi_i^\mu s_i$ に着目する。これを初期パターンを変えて複数回繰返し、全ての重なり度の合計をフィットネス値とする。

3. シミュレーションと結果

数値実験において我々の用いたパラメータ値は以下の通りである。個体数は $M=50$ とし、選択ではフィットネス値の高い個体から順に10選び、各個体は、ランダムな突然変異を伴った遺伝子型のコピーを5個体、子孫として残す。ただし突然変異率は0.004とした。遺伝子型の各パラメータ範囲は、 $0 \leq x, y \leq 1, 0 \leq \alpha \leq 2\pi, 0 \leq \theta \leq \pi/3, 0 \leq d \leq 0.15, -2 \leq b \leq 2, 0 \leq a \leq 2$ とした。Axonの分岐は5回とし、ニューロンの近傍は $r=0.05$ に固定した。記憶パターンは 7×7 のもの4個、従って総ニューロン数は $N=49$ である。学習則はHebb則： $\delta w_{ij}(t_L) = \lambda \sum_{\mu=1}^p \xi_i^{\mu} \xi_j^{\mu}$ を用いた。ただしニューロン $i \rightarrow j$ の接続がない場合、 $\delta w_{ij} = 0$ である。ここで λ は「学習効率」で、後天的な学習の強度を表す。学習期間は $t_L=15$ までとし、想起タスクの評価にはその時間発展の $t=5, 10, 15$ において重なり度を取った。想起タスクにおける初期パターンとしては目標パターンに5%のノイズを加えたものを取った。想起タスクはノイズを変えて4回繰り返した。

Fig.2は学習効率を $\lambda=0.002$ と $\lambda=0.05$ とした場合の、各世代での最大フィットネス値の推移である。ただしフィットネス値は最大1000に正規化してある。

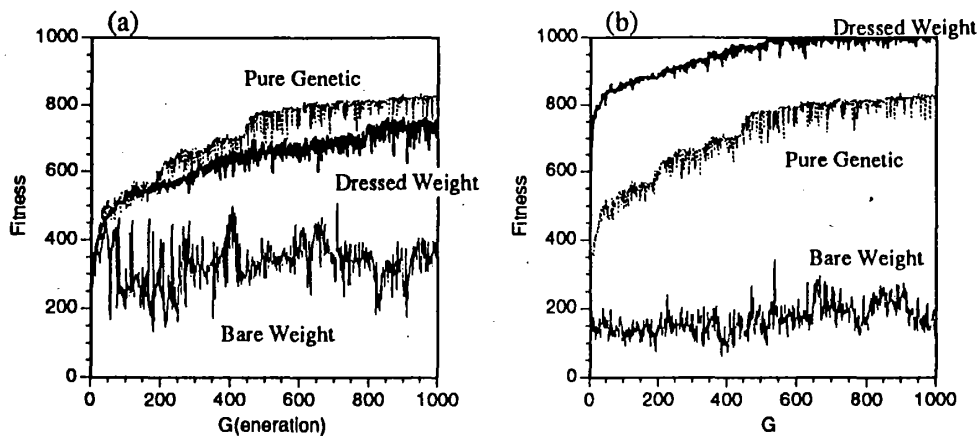


Figure 2: 最優秀個体のフィットネス値進化。(a) $\lambda=0.002$. (b) $\lambda=0.05$.

Fig.3は $\lambda=0.05$ のときの第0世代と第1000世代におけるネットワークの結合構造である。




Figure. 3: 第0世代と第1000世代における最優秀個体のネットワーク接続構造 ($\lambda=0.05$)

またFig.4は $\lambda=0.05$ のときの第0世代と第1000世代におけるDressedウェイトのニューロン間距離-ウェイト値の分布図である。

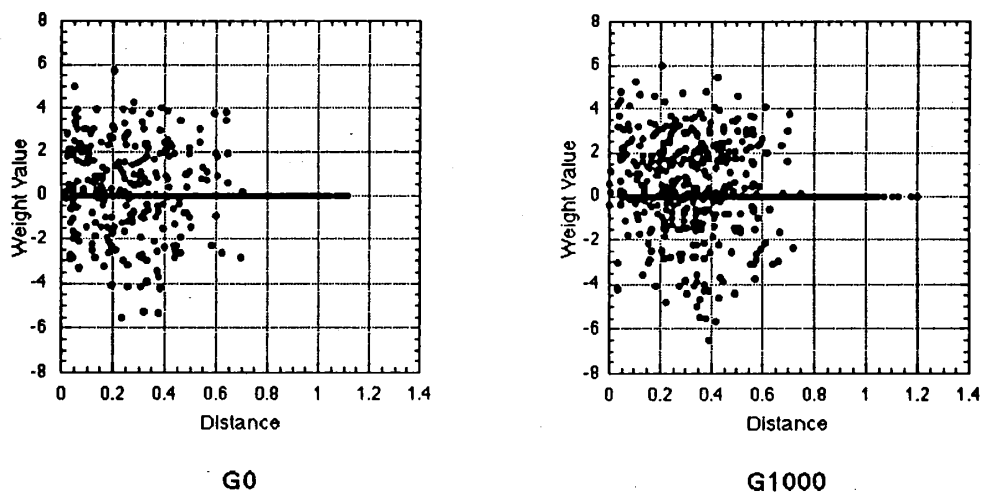


Figure 4: G0とG1000における最優秀個体の、接続ニューロン間の距離とDressedウェイト値との相関。 ($\lambda=0.05$)

数値実験の結果とHopfieldモデルとの比較をあげておく。以下HはHopfieldモデルを指し、Eは $\lambda=0.05$ のときの第1000世代の最優秀個体を指す。全結合数はH:2352とE:406、従って1ニューロンあたりの平均結合数は、H:48とE:8.29となる。つまりEは非常に希薄な結合を形成している。 $\eta = \sum_{i,j} w_{ij} w_{ji} / \sum_{i,j} w_{ij}^2$ によって定義される対称パラ

メタ-の値はH:1.0, E:0.23、すなわちEはかなり非対称なウェイトをもつ。フィットネス値についてはFig.2にも見られるとおりEがどの5%ノイズパターンに対しても100または100近くのフィットネス値を獲得するのにたいし、Hは平均で88.3の値を獲得するにすぎない。もちろんこの結果は記憶=想起すべきパターンを限定した場合のものであるから、単純にEがHに勝るというものではないが、われわれの進化論的アプローチによって得られたニューラル・ネットワークが、その構造においてHopfieldモデルと全く異なるにもかかわらず、十分な連想記憶能力を持ち、かつHopfieldモデルを越える可能性をも示していると考えられる。

4. おわりに

我々はGrowing Neuronによって形成され、遺伝的アルゴリズムに従って進化する相互結合型ネットワークモデルを構築し、その連想記憶能力をシミュレーションによって示した。得られたネットワークは、ニューロンの結合数・ウェイトの対称性の点でHopfieldモデルと著しく異なるにもかかわらず、連想記憶能力は十分、あるいはHopfieldモデルを上回ることが可能である。

現在我々はタスクパターンの組を増やし、パターン組の与え方を変化させること、すなわちタスク変化による動的環境を導入することによる影響を調べているが、これによって期待されるのはタスクの特殊性を除外とともに、学習と進化の相関の考察を可能とすることである。

さらに将来の課題として興味深いのはニューロンの位置決定に関する発生論的な観点、アポトーシスの導入、あるいは、Axon成長の際の目標ニューロンからの成長因子の存在などをモデルに組み込むことがあげられよう。

以上の内容およびさらに詳しい参考文献については、文献[5]もご参照ください。

参考文献

- [1]J.J. Hopfield, Proc. Natl. Acad. Sci. USA 79 (1982), 2554.
- [2]X. Yao, Int. J. Neural Systems Vol. 4 (1993), 203.
- [3]S. Nolfi & D. Parisi: "Growing Neural Networks", Technical Report PCIA-91-15,
- [4]S. Nolfi, O. Miglino & D. Parisi: "Phenotypic Plasticity in Evolving Neural Networks", Technical Report PCIA-94-05
- [5]S. Fujita & H. Nishimura: "An Evolutionary Approach to Associative Memory in Recurrent Neural Networks", KOBE-TH-94-07, HUIS-94-03 (1994) (To be published in Neural Processing Letters).