

## 神経細胞置換を取り入れたニューラルネットワークモデル

若木 裕子 †

† 山梨大学大学院医学工学総合教育部

服部 元信 ‡

‡ 山梨大学大学院医学工学総合研究部

### 1 はじめに

我々は、日常的に多くの情報を記憶することができる。これには、海馬と呼ばれる領域が関与しており、海馬は過去数年間の記憶の貯蔵庫であることが知られている。そのため、海馬構造には限られたネットワークにおいて、大きな記憶容量を実現するための仕組みがあると考えられる。また、人間は逐次的に学習を行うため、海馬では追加学習が行われていることが推測できる。従来の連想記憶モデルにおいては、追加学習と記憶容量の確保の両立は困難な問題であった。従って、上記のように推測される海馬機能を実現する仕組みを解明することは極めて重要であると考えられる。

海馬構造を利用した連想記憶モデルの研究の1つに、Fellenzが提案したHLAM (Hidden Layer Associative Memory) の拡張モデルがある [1]。しかし、記憶の形成に関与が示唆される近年発見された海馬の神経細胞置換 (Neuronal Turnover) が考慮されていない。そこで、本研究では神経細胞置換を含む海馬構造を考慮したニューラルネットワークモデルの作成を新たに行い、追加学習によりモデルの記憶容量調査を行う。そして神経細胞置換と記憶容量の相関関係を調べる。

### 2 海馬構造

海馬は脳の中央に位置しており、主に DG (Dentate Gyrus), CA3, CA1 で構成される領域である。海馬と外部をつなぐ領域として EC がある。EC は多層構造であり、海馬の入出力層として機能している。EC と海馬の各領域、DG と CA3, CA3 と CA1 はそれぞれ領域間に結合をもち、CA3 は自己結合をもつ。生理学的知見より、EC から各領域への結合率は 25%，また、DG から CA3 への結合率は 4% で非常に強力でまばらである。さらに、CA3 の自己結合や CA3 から CA1 への結合は全結合である。また、電気生理学的知見より、学習時には EC-DG-CA3-CA1 が、想起時には EC-CA3-CA1 が支配的になることが分かっている [2]。これより、学習時にのみ支配的に使用される DG は記憶の形成（学習）に関与していると考えることができる。その DG において近年、神経新生 (Neurogenesis) が発見された。これにより、DG では神経細胞の新生と死滅が繰り返し起きていることがわかった。これを神経細胞置換と呼ぶ。具体的には、ラット海馬では 1 日で DG の全神経細胞の約 1% が神経細胞置換により新しい神経細

胞に生まれ変わっている。

### 3 神経細胞置換を取り入れたニューラルネットワークモデル

本研究で提案するモデルは、EC, DG, CA3 の 3 層からなり、それぞれ入力層、隠れ層、出力層として機能する。モデルの構造を図 1 に示す。各層のニューロン数は、EC, DG, CA3 の順に 240, 1600, 480 とした。それぞれの層間の結合率は図中に示したとおりである。そして各領域の発火率は、EC を 10%, DG を 1%, CA3 を 4% とした。本研究ではデータは (0,1) の 2 値を扱い、発火ニューロンは 1、非発火ニューロンは 0 とした。各層の発火率とは、層の全ニューロン数に対する 1 の割合のことである。各ニューロンの入力重み和は式 (1) で求め、出力は  $k$ -WTA (Winner-take-all) 抑制によって決定した。 $k$ -WTA 抑制は、層の全ニューロンの入力重み和を降順に  $k$  個選択し、選択されたニューロンは出力を 1、それ以外のニューロンは出力を 0 とする方法である。 $k$  は CA3 を例に挙げると、ニューロン数 480 で発火率 4% のので、これを満たす 20 個となる。EC-CA3, EC-DG, DG-CA3 の結合重みの学習には Hebb 則を改良した Oja 則を用いた (式 (2))。

$$y_j = \sum w_{ij}x_i \quad (1)$$

$$\Delta w_{ij} = \eta \times y_j(x_i - y_j w_{ij}) \quad (2)$$

ここで、 $x_i$  は情報を送る層のニューロン、 $y_j$  は情報を受け取る層のニューロン、 $w_{ij}$  は  $x_i$  と  $y_j$  間の結合重みを表す。CA3 の自己結合重みの学習は式 (3) の相關学習を用いた。各ニューロンの状態は同期更新させた。

$$w_{ij} = \sum_{m=1}^M x_i^{(m)} x_j^{(m)} \quad (3)$$

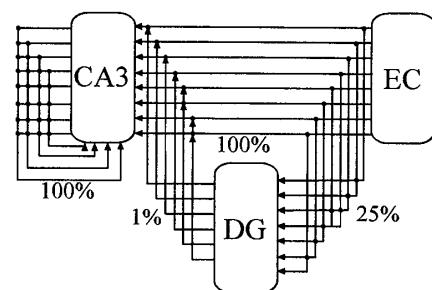


図 1: 神経細胞置換を取り入れたニューラルネットワークモデルの構造

A neural network model with neuronal turnover.

†Yuko WAKAGI ‡Motonobu HATTORI

†Interdisciplinary Graduate School of Medicine and Engineering,  
University of Yamanashi

‡Interdisciplinary Graduate School of Medicine and Engineering,  
University of Yamanashi

ここで,  $M$  は入力パターン数である. また, 生体の海馬の DG から CA3 への結合は非常に強力である. そのため, EC から CA3 への入力よりも DG からの入力の影響力を大きくするため, DG からの入力重み和を 10 倍にした. ここで, DG における神経細胞置換のモデル化を説明する. まず, ランダムに DG の全ニューロンの  $\alpha\%$  のニューロンを選択する. 選択したニューロンと EC, DG との結合を全て消去する. この処理はニューロンの死滅を表す. 次にニューロンの新生を行う. 新生は, 結合を消去したニューロンに, 結合率の制約を満たすように新しい結合を作成することにより行う. さらに, 学習と想起で支配的になる領域が異なる生体の海馬にならって, 学習時と想起時に使用する領域を変更した. 学習時には EC, DG, CA3 の 3 層を, 想起時には EC, CA3 の 2 層を用いた. モデルにおける各層間の結合率と学習の有無, 学習則は計算機シミュレーションによる予備実験を行い決定した.

## 4 記憶容量

### 4.1 シミュレーション条件と方法

計算機シミュレーションでは, (0,1) の 2 値で発火率 10%, 240 次元のパターンを入力とした. そして, さまざまな入力に対するモデルの能力を調べるために, パターン間の類似度(方向余弦)平均が 0.08, 0.28, 0.39, 0.53, 0.62, 0.92 の 6 種類のパターン群を用意した. また, 各層間の結合は結合率を満たすようにランダムに, 結合重みの初期値は 0.25 から 0.75 の間で設定した.

本実験では, 学習パターン数  $N$  を 1 から 1 つずつ増加させ, その都度学習と想起を行い, 全てのパターンを完全に想起できる  $N$  の上限値を記憶容量とした. つまり, 記憶容量とは学習した全パターンを完全想起できる最大のパターン数のことである. 学習の手順は, 1 パターンを 20 回学習し, DG 層で神経細胞置換を行い, 次のパターンの学習を行うというように, 追加学習を行った. そして, 想起は, 学習時と想起時に CA3 に形成されたパターンが同じであれば成功とした. これを 1 試行として 10 試行の平均による記憶容量を求めた. また, 神経細胞置換の割合をそれぞれ 0~100%まで 10%毎に変化させた.

### 4.2 神経細胞置換の割合と記憶容量の関係

記憶容量調査の結果を図 2 に示す. 横軸が神経細胞置換の割合 (%), 縦軸が全パターン完全想起成功数(記憶容量)である. そして, 図中の数値は入力パターン間の類似度平均である. 図 2 より, 6 種類の入力パターンにおいて, 神経細胞置換があるときの記憶容量は, 神経細胞置換がないときの記憶容量よりも大きかった. また, 神経細胞置換の増加に伴い, 記憶容量のグラフに右上がりの傾向が見られた. 類似度平均 0.53 の試行では, 神経細胞置換の割合 0% から 100% の増加で記憶容量に約 10 パターンの増加が見られた.

次に, 学習パターン数を 10 とし, 神経細胞置換の割合を変化させたときに, CA3 に形成されるパターンの平均類似度がどのように変化するのかを調べた(図 3). 全入力パターンに対して, 神経細胞置換がない場合でも, CA3 に形成されたパターンの類似度平均は, 入力パターンの

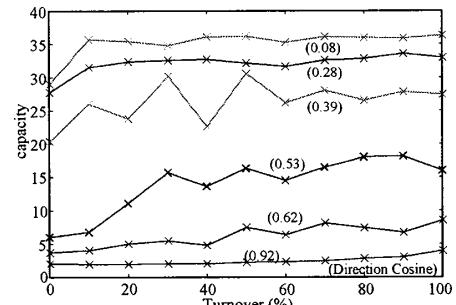


図 2: 神経細胞置換の割合と記憶容量の比較

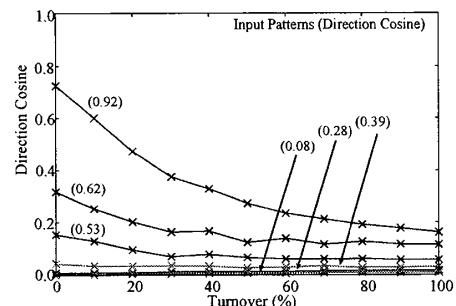


図 3: 神経細胞置換の割合と CA3 パターンの平均類似度の比較

類似度平均よりも低かった. さらに, 神経細胞置換の割合が増加することで, 類似度平均は大幅に低下した. これより, 本モデルでは, 神経細胞置換によりパターンの分離度を上げることで, 類似した入力を類似度の低い入力に変換して学習を行っていることができる.

## 5 まとめ

本研究では, 連想記憶モデルにおける追加学習と記憶容量確保の両立が, 海馬の構造と神経細胞置換により可能であると推測した. そして, これらを取り入れたニューラルネットワークモデルを作成し, 追加学習による記憶容量調査を行った. その結果, 神経細胞置換の増加はパターン分離能力を上げ, 追加学習を容易にすることが分かった. これにより, 神経細胞置換の増加に伴い記憶容量が増加したと考えられる. 今後は, 耐雑音性の調査を行い, 神経細胞置換が人間の強力な連想能力に関与しているのかを調査する.

## 参考文献

- [1] W. A. Fellenz and J. G. Taylor, The hidden layer associative memory model of hippocampus, Proceeding of the International Joint Conference on Neural Networks 2000, IEEE Press, pp.205-210, 2000.
- [2] M.F. Yeckel, and T.W. Berger, Feedforward excitation of the hippocampus the trisynaptic pathway, Proceedings of the National Academy of Sciences of the USA, Vol.87, pp.5832-5836, 1990.