シナプス間の相互作用を考慮したニューロンモデル

非会員 唐 政 (富山大学)

非会員 田村 宏樹 (宮崎大学)

非会員 石塚 興彦 (宮崎大学)

非会員 淡野 公一 (宮崎大学)

A Neuron Model with Interaction among Synapses

Zheng Tang, Non-member (Toyama University), Hiroki Tamura, Non-member, Okihiko Ishizuka, Non-member, Koichi Tanno, Non-member (Miyazaki University)

This paper describes a neuron model with interaction among synapses. This model is based on the morphogenesis of dendrite and the nonlinear interactions between excitatory and inhibitory synapses on dendrite in retinal ganglion cells, which were not considered in traditional neuron models. The neuron model consists of a three-layer network: connection layer, AND layer and SOMA layer. The nonlinear interactions are idealized to be logical AND operations and neuron cells to be logical OR operations. The types of inputs from other cells are described as a connection function and determined by a back-propagation based learning. We can know the morphogenesis of dendrite, the location of synapses and the types of the synapse's connection from simulations on learning. Simulations show that this model can learn Exclusive-OR problem and other complicated problems with only one neuron.

キーワード：ニューロンモデル, 樹状突起, シナプス, 相互作用, バックプロパゲーション

1. はじめに

神経回路網に類似したメカニズムによる情報処理の研究は、脳の情報処理様式を明らかにする研究として始まった。今世紀初頭、Golgi、Cajalらによって、脳の神経回路網が、たくさんの神経細胞（ニューロン）の結合したものであることが明らかにされ⁽¹⁾、また神経細胞の中を電気的なインパルスが伝搬することによって情報が伝達されていることなどが明らかになった⁽²⁾⁽³⁾。こうした解剖学、生理学の成果に刺激される形で、McCullochとPittsが非常に簡単なニューロンのモデルを提案し、それを少数結合した回路網によって論理関数の計算ができることを示した⁽⁴⁾。このモデルは基本的に樹状突起における局所的な作用を考慮せず、シナプスもそれぞれ独立で、単なる荷重結合としている。しかし、近年、ほ乳類小脳のプルキンエ細胞や海馬の錐体細胞での研究から、樹状突起は単にシナプス入力を荷重する役割だけでなく、その枝上のチャネルなどの機能によって神経細胞の演算過程に積極的に関与していることがわかってきた⁽⁵⁾。また、樹状突起にはシナプス結合間の非線形な相互作用も存在すると言われる。Koch、PoggioとTorreらは、網膜細胞節細胞における樹状突起上のシナプ

ス結合間に作用する非線形相互作用と樹状突起の枝分かれの形状を論理的AND、OR、NOTで表し、より高度な演算処理が可能なニューロンモデルを提案した⁽⁶⁾。しかし、樹状突起にしてもその形態は一樣ではなく、様々な形態をしている⁽⁷⁾⁽⁸⁾。シナプス結合間の相互作用も複雑で、それぞれのシナプスに対して、相互作用の有無、相互作用の種類などを確定する方法はない⁽⁹⁾。

著者らは、樹状突起における非線形作用を論理的なネットワークAND-OR標準加法形によって表し、学習によって樹状突起の形状、シナプス間の相互作用の種類などを推測できるニューロンモデルを提案した⁽¹⁰⁾。しかし、このモデルは基本的に細胞体から伸びている樹状突起が1本だけと仮定している。従って、本論文では、樹状突起を任意本で、形態も任意で、すべてのシナプス間に相互作用があると仮定し、それを論理的積（AND）で表し、学習によって不要なものを淘汰し、有用なものを強化固定し、成熟した機能の樹状突起を形成するニューロンモデルを提案する。本論文で提案するモデルは樹状突起の形態、シナプス間の相互作用などを考慮したもので、1層で線形分離不可能な問題に対応できることなどから、従来のMcCulloch & Pittsのモデルより生体の情報処理に忠実である。更に、提案す

図 1 生体における神経細胞
Fig. 1. Schematic view of a neuron

図 2 MuCulloch & Pitts ニューロンモデル
Fig. 2. MuCulloch & Pitts's neuron model

るモデルは従来のモデルより複雑ではあるが、論理演算の AND、OR だけでの論理構成ができるのでハードウェア化に適していると言える。また、このモデルは学習により、抑制性と興奮性のシナプス結合の位置や樹状突起の形状がわかる。この学習で得られた結果が生物学者にとって有益な示唆を与えることと期待している。

2. MuCulloch & Pitts モデル

〈2・1〉人工ニューロンモデル 生体における神経細胞は図 1 に示すように、細胞体 (soma)、樹状突起 (dendrite)、軸索 (axon) の 3 つの部分から構成されている。人工ニューロンは生体ニューロンの基本的な特性を模倣するように設計されている。人工ニューロンには、それぞれが他のニューロンの出力を表すような入力を与えられる。各入力には、生体ニューロンのシナプス強度に相当する重みが掛けられる。そして、すべての重み付き入力が総和され、ニューロンの出力が決まる。図 2 はこのような考え方に基づくモデルを示している。ネットワークパラダイムの多様性にもかかわらず、ほとんどすべてのネットワークはこのような形態に基づいている。ここで、 $x_1, x_2, \dots, x_n$ で示される入力が人工ニューロンに与えられる。各入力信号には、それぞれの信号に対する重み $w_1, w_2, \dots, w_n$ が掛けられる。各重みは、生体シナプス結合の“強さ”に対応する。それから、生体の細胞体に相当する人工ニューロンは重み付き入力を総和し、活性化関数 f によって処理され、ニューロンの出力信号が生成される

$$y = f\left(\sum_{j=1}^n w_{ij}x_j - \theta_i\right) \dots\dots\dots (1)$$

ここで、 f はユニットの出力関数で、一般的に非線形関数である。 θ は閾値である。 $w \geq 0$ のときは興奮性シナプ

ス結合、 $w < 0$ のときは抑制性シナプス結合である。この出力関数としてよくシグモイド関数が用いられる。その関数は、

$$f(x) = \frac{1}{1 + e^{-kx}} \dots\dots\dots (2)$$

で表される。また、シグモイド関数は k の値を大きく設定することによって、ステップ関数と同じ特性を持つ。そのステップ関数は、

$$f(x) = \begin{cases} 1 & (x \geq 0) \\ 0 & (x < 0) \end{cases} \dots\dots\dots (3)$$

で表される。出力が 1 のときそのニューロンは興奮状態であり、出力が 0 のときニューロンは静止状態であることを示している。このように時間的離散モデルで、かつ出力信号を 0, 1 のみで表したモデルは 1943 年に MuCulloch & Pitts により、はじめてニューロンモデルとして発表されたもので、ニューロンのモデルとして最も基本的で古典的なニューロンモデルである。

現在でも、ニューロンモデルでは非常に簡単な MuCulloch & Pitts モデルが用いられている。この単純なニューロンモデルがそれぞれ結合したネットワークにより生体の神経回路網の機能をとらえ、工学的に応用がなされている。この単純なニューロンモデルは多層型にネットワーク形成されることで複雑な問題も解決できるようになっている。線形分離不可能な問題 (例えば EX-OR) に対しても、パーセプトロンの多層化ネットワークの処理で実現可能となっている⁽¹¹⁾。しかし、実際に生体の神経回路網に触れながら実験を行なっている研究者の間では、個々のニューロン単位でもずっと複雑な情報処理が行なわれているという知見がある⁽¹²⁾。

3. シナプス間の相互作用を考慮したニューロンモデル

〈3・1〉樹状突起の機能 近年、ほ乳類小脳のプルキンエ細胞や海馬の錐体細胞での研究から、樹状突起は単にシナプス入力を荷重する役割だけでなく、その枝上のチャネルなどの機能によって神経細胞の演算過程に積極的に関与していることがわかってきた⁽⁵⁾。

また、猫の網膜神経節細胞は形態学的分類 (細胞体の形状、樹状突起の枝分かれなど) により α 細胞、 β 細胞、 γ 細胞、 δ 細胞に分類でき、その中で γ 、 δ 細胞の樹状突起にはスイッチ作用型の強い抑制性シナプスが存在し、その抑制性結合は興奮性の信号を完全に遮断することができるという知見がある⁽⁶⁾。そのことが、網膜神経節細胞における樹状突起での強い非線形相互作用の原因であると推測されている。

さらに、神経細胞の樹状突起上には、リセプタと呼ばれるある特定のイオンのみを取り入れる受容体が存在し、その受容体にイオンが入って来ることにより電位が変化する。

図3 理想化した樹状突起の相互作用
Fig. 3. The interaction of idealized dendrite

その反応する受容体の種類によって興奮性の結合か抑制性の結合か決定する。このシナプス結合とシナプス結合との間には、抑制的な非線形相互作用が起こるという知見もある^{(6) (13)}。

これらのことから、樹状突起の機能は従来考えられていた線形荷重としての機能だけではなく、非線形なシナプス間の相互作用による神経細胞の演算過程にも関与していることがわかってきた^{(6) (13)}。この樹状突起の機能によって神経細胞の情報処理は複雑化していると思われる。樹状突起の機能を反映するためには単なる荷重よりもっと高度な演算処理が必要であると思われる。

〈3・2〉 Koch, Poggio and Torre モデル 前節で述べたことを基に、Koch, Poggio and Torre は、樹状突起の機能を次のような理想化した。

1本の樹状突起に接続するすべてのシナプス間に相互作用があるとする。その樹状突起に1つでも抑制性シナプス結合が存在し、かつ、その抑制性シナプス結合に信号が入力されれば、他のシナプス結合がどのような状態でもその樹状突起からの細胞体への出力はないものとする。つまり、抑制性シナプス結合は信号を遮断するスイッチ作用があるとする。そのことによって、理想化した樹状突起では強い非線形相互作用が実現可能となった。

この相互作用のモデルを図3の樹状突起(a)に示す。樹状突起に興奮性と抑制性のシナプス結合が並列に1つずつある場合、細胞体へ伝わる信号はどのようなになるかモデルにより説明する。ここで、 e は興奮性シナプス結合への信号、 i は抑制性シナプス結合への信号、 y は細胞体への信号とする。それぞれの信号は0,1のデジタル信号である。

興奮性シナプス結合から e の信号が細胞体へ伝わるためには抑制性シナプス結合への信号 i がないことが条件になる。すなわち、細胞体への信号が $y = 1$ になるには、 $i = 0$ かつ、 $e = 1$ の時である。それを論理式で表すと、次式で表される。

$$y = e \cdot \bar{i} \dots\dots\dots (4)$$

さらに、図3の樹状突起(b)の場合を考える。樹状突起に興奮性のシナプス結合が1つ、抑制性のシナプス結合が2つある場合、細胞体へ伝わる信号はどのようなになるかモデルにより説明する。

興奮性シナプス結合から e の信号が細胞体へ伝わるため

には抑制性シナプス結合への信号 i_1, i_2 がないことが条件になる。すなわち、細胞体への信号が $y = 1$ になるには、 $i_1 = 0$ かつ、 $i_2 = 0$ かつ、 $e = 1$ の時である。それを論理式で表すと、次式で表される。

$$y = e \cdot \bar{i}_1 \cdot \bar{i}_2 \dots\dots\dots (5)$$

これらの論理式より、この相互作用のモデルによるシナプス間での相互作用はAND演算として考えられる。しかし、樹状突起にしてもその形態は様ではなく、様々な形態をしている。シナプス結合間の相互作用も複雑で、それぞれのシナプスに対して、相互作用の有無、相互作用の種類などを確定する方法はない。そこで、著者らは、1本の樹状突起における非線形相互作用を論理的ネットワーク（標準加法形）で表し、学習によって樹状突起を形成することを計った⁽¹⁰⁾。しかし、そのネットワークは1本の樹状突起における非線形相互作用に基づくものであり、任意本の樹状突起に対応するためにはかなり複雑な構成になる。

〈3・3〉 シナプス間の相互作用を考慮したニューロンモデル 本論文では、樹状突起の形態、シナプス間の相互作用などを考慮したニューロンモデルを提案する。このモデルは、従来のMuCulloch & Pittsモデルのような樹状突起の機能を全く考慮していない非常に簡単な処理を行うニューロンモデルより、ニューロンで最も重要な情報処理をしていると考えられる樹状突起の機能を理想化し論理的に表した処理を組み込んでいますので、より生体のニューロンの情報処理に忠実であると言える。それにより、従来のMuCulloch & Pittsモデルでは単なる荷重結合であって、樹状突起の形状や、樹状突起上でのシナプス間の相互作用を考慮できなかったが、提案するニューロンモデルではそれらの機能を実現できている。また、学習によって、樹状突起の形状やシナプスの位置や種類などを推測することができる。それは学習によって不要なものを淘汰し、有用なものを強化固定し、成熟した機能の樹状突起を形成するニューロンの機能を反映している。ここでは、まずニューロンの動作を次のように一般化する。

- (1) 初期の樹状突起の形状は任意である。
- (2) 他のニューロンはそれぞれのシナプスを通じてすべての樹状突起に接続し、同じ樹状突起に接続するすべてのシナプス間に相互作用がある。
- (3) 樹状突起に生じる非線形作用は論理的な積(AND)で表す。
- (4) 最後成熟した樹状突起の形状、シナプス間の相互作用の種類などすべては学習によって決まる。

ここで、本論文で提案したシナプス間の相互作用を考慮したニューロンモデルを図4に示す。このネットワークは3層構造をしている。第1層は接続層と呼び、外部からの入力X(他のニューロンからの入力状態)を受けて、樹状突起へ伝える(神経細胞でいえば、シナプスの種類である興奮性か抑制性に当たる部分である)。第2層はAND層と呼び、接続層からさまざまな結合を論理的ANDを取り(神

経細胞でいえば、樹状突起の1部に当たる部分である)、第3層に送る。第3層はAND層から送られてきた信号の線形荷重和を取り、閾値処理をして0、1のデジタル信号として出力する層であり、SOMA層と呼ぶ。ここで、SOMA層は、閾値と荷重を0.5と1とすると、1つの樹状突起から信号($y = 1$)が入力されたら、1のデジタル信号を出力するように設定することができる。もちろん、他の荷重または閾値の設定も可能である。従って、SOMA層は論理的ORの働きをしている。そのことによって、このネットワークは論理的AND-OR構成になる。

一方、入力とANDゲート間の接続関係は次のような接続状態によって表現される⁽¹⁴⁾。

- (1) 抑制性シナプス結合
入力信号を反転して樹状突起へ伝える。
 - (2) 興奮性シナプス結合
入力信号をそのまま樹状突起へ伝える。
- 入力はすべてのANDゲートに与えられる初期設定をしていることから次の接続状態も考慮する必要がある。

- (3) 常に1を接続
ある入力がある枝に結合がない(影響なし)ときは、入力によらず常に1を樹状突起へ伝える。これは、常に1である信号がANDゲート後の出力に影響がないことに起因する。そのモデルを図5に示す。

- (4) 常に0を接続
無駄な枝(ANDゲート)を減らすため、入力によらず常に0を樹状突起へ伝える。これは、常に0である信号によりANDゲート後の出力が常に0であるためORゲートに影響がない、つまり、ANDゲート(枝)がないことと等しい。樹状突起や軸索が発芽し、ある細胞の樹状突起とシナプス結合するのはその細胞の発生当初に遺伝的に決められていると考えられている。しかし、ある時期になると環境に応じて学習し必要な結合が残り、不必要なものは消えていくと考えられている。このシナプス結合がなくなり、必要なものだけが残るということを常に0を伝えることで実現している。そのモデルを図6に示す。

本モデルは、ブール代数によると、第2層ANDの数が充分であれば、上述の接続状態の組合せによって任意な論理関数を表現できる。すなわち、どんな複雑な樹状突起における非線形相互作用も表せる。例えば、入力を n とすると、任意な樹状突起における非線形相互作用を表現するために、最大 2^{n-1} 個ANDゲートがあればよいということになる⁽¹⁴⁾。

4. 学習アルゴリズム

前章で述べたように、任意の樹状突起における非線形相互作用は図4に示す3層の論理的ネットワークと細胞体によって構成できる。しかも、その具体的な構成等はすべて学

図4 一般化した論理的ネットワークによるニューロンモデル

Fig. 4. Generalized neuron model with logic network

図5 常に1が伝わる場合
Fig. 5. The constant 1 connection

図6 常に0が伝わる場合
Fig. 6. The constant 0 connection

習によって形成できる。学習は基本的にバックプロパゲーション学習則を用いられるが、各層のユニット関数においては、接続関数は不明であり、更に論理的ANDも微分不可能であるため、次のように処理する。

〈4・1〉 接 続 層 接続層は樹状突起におけるシナプス結合間の相互作用を表す層であり、その相互作用は4つの接続状態、常に0を接続、常に1を接続、入力を反転して接続と入力をそのまま接続が必要になる。入出力は0、1と考え、その接続状態は次の関数(シグモイド関数)

$$Y = f(u) = \frac{1}{1 + e^{-ku}} \dots\dots\dots (6)$$

で表せる。ここで、 $u = wX - \theta$ であり X が入力で w 、 θ は接続パラメータである。 Y はシナプス結合から樹状突起への出力である。また、 k は定数である。定数 k を大きくするとシグモイド関数はステップ関数に非常に近くなる。

- (1) 常に0を接続図7(a)、例えば $w = 1.0, \theta = 1.5$ であるとき($0 < w < \theta$)、入力が0、1のどちらでもシグモイド関数の出力は0である。また、図7(b)の $w = -1.0, \theta = 0.5, 1.5$ であるとき($w < 0 < \theta$)も同様にシグモイド関数の出力は0である。
- (2) 常に1を接続図7(e)、例えば $w = 1.0, \theta =$

図7 シグモイド関数による接続状態

Fig.7. Sigmoid function output characteristics and its equivalent connection states

$-0.5, -1.5$ であるとき ($\theta < 0 < w$)、入力が 0、1 のどちらでもシグモイド関数の出力は 1 である。また、図 7(f) の $w = -1.0, \theta = -1.5$ であるとき ($\theta < w < 0$) も同様にシグモイド関数の出力は 1 である。

(3) 入力を反転して接続図 7(c)、例えば $w = -1.0, \theta = -0.5$ であるとき ($w < \theta < 0$)、入力が 0 のときは出力 1、入力が 1 のときは出力 0 である。よって入力の反転が出力となる。

(4) 入力をそのまま接続図 7(d)、例えば $w = 1.0, \theta = 0.5$ であるとき ($0 < \theta < w$)、入力が 0 のときは出力 0、入力が 1 のときは出力 1 である。よって入力のそのまが出力となる。

である。従って、接続関数のパラメータ w と θ の調整によって、必要な接続状態が作られる。

〈4・2〉 AND 層 第 2 層の AND 層は論理的演算であり、微分は不可能である。ここで AND 関数を次の soft-minimum 関数

$$AND = f_{min} = \frac{Y_1 e^{-uY_1} + Y_2 e^{-uY_2}}{e^{-uY_1} + e^{-uY_2}} \quad \dots\dots\dots (7)$$

で近似する。ここで、入力変数は x_1, x_2 の 2 つとし、 u は定数としている。図 8 は soft-minimum 関数は変数 x_2 を 1 に固定したときのものである。図からこの関数は論理関数 AND

図8 soft-minimum 関数

Fig. 8. The characteristics of the two-variable soft-min function with $X_2=1$

の近似として考えて良い。定数 u を大きくすると AND に非常に近くなる。

〈4・3〉 SOMA 層 SOMA 層は入力の線形荷重和を取り、閾値処理をして 0、1 のデジタル信号として出力する層であり、次の関数 (シグモイド関数)

$$g = \sum_{j=1}^N AND_j \cdot w_{soma\ j} - \theta_{soma} \quad \dots\dots\dots (8)$$

$$O = f(g) = \frac{1}{1 + e^{-vg}} \quad \dots\dots\dots (9)$$

で表せる。ここで、 $w_{soma\ j}, \theta_{soma}$ は SOMA 層の荷重、閾値である。この荷重と閾値を 1 と 0.5 に設定することにより、SOMA 層は論理的 OR にかかなり近い働きをさせることができる。

従って、図 4 におけるニューロンモデルのすべての層は微分可能になり、連続関数によるバックプロパゲーション学習則に従って接続層の接続パラメータ w と θ を修正し、学習を行うことができる。

〈4・4〉 学習アルゴリズム ここで、入力に対する理想出力である教師信号 T が与えられる。入力を与えたときの実際の出力を O とし、次式に示すような理想出力と実際の出力との平均自乗誤差を誤差関数 E とする。

$$E = \frac{1}{2} (T - O)^2 \quad \dots\dots\dots (10)$$

このニューロンモデルにおいて学習の対象となるのは、接続関数の接続パラメータ w と θ だけである。このパラメータを修正して誤差関数の E を減少するように学習を行なう。この誤差関数の E の値を減少させる方法として最急降下法を用いると、次式に示すように接続パラメータを修正することにより誤差 E は減少していく。

表 1 学習パラメータ

Table 1. The learning paramters

The learning constant η	0.1
The positive constant k of sigmoid function	4.0
The positive constant u of softmin function	4.0
The positive constant v of SOMA function	3.0

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}} \dots\dots\dots (11)$$

$$\Delta \theta_{ij} = -\eta \frac{\partial E}{\partial \theta_{ij}} \dots\dots\dots (12)$$

ただし、 $\eta > 0$ である。

ここで、 $\partial E / \partial w_{ij}$ は、次のように偏微分の合成で表すことができる。

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial O} \cdot \frac{\partial O}{\partial AND_j} \cdot \frac{\partial AND_j}{\partial Y_{ij}} \cdot \frac{\partial Y_{ij}}{\partial w_{ij}} \dots\dots (13)$$

同様に、 $\partial E / \partial \theta_{ij}$ も、次のような偏微分の合成で表すことができる。

$$\frac{\partial E}{\partial \theta_{ij}} = \frac{\partial E}{\partial O} \cdot \frac{\partial O}{\partial AND_j} \cdot \frac{\partial AND_j}{\partial Y_{ij}} \cdot \frac{\partial Y_{ij}}{\partial \theta_{ij}} \dots\dots (14)$$

ここで、 Y, AND, O は、それぞれの接続層からの出力信号、樹状突起の枝における相互作用後 (AND) の出力信号、細胞体からの出力信号である。各偏微分を求めると、

$$\frac{\partial E}{\partial O} = O - T \dots\dots\dots (15)$$

$$\frac{\partial O}{\partial AND_j} = \frac{vw_{soma_j} e^{-v(\sum_{j=1}^N AND_j w_{soma_j} - \theta_{soma})}}{(1 + e^{-v(\sum_{j=1}^N AND_j w_{soma_j} - \theta_{soma})})^2} \dots\dots (16)$$

$$\frac{\partial AND_j}{\partial Y_{ij}} = \frac{\sum_{l,m} (1 - uY_{ij} + uY_{lm}) e^{-u(Y_{ij} + Y_{lm})}}{(\sum_{l,m} e^{uY_{lm}})^2} \dots\dots (17)$$

$$\frac{\partial Y_{ij}}{\partial w_{ij}} = \frac{kX_i e^{-k(X_i w_{ij} - \theta_{ij})}}{(1 + e^{-k(X_i w_{ij} - \theta_{ij})})^2} \dots\dots\dots (18)$$

$$\frac{\partial Y_{ij}}{\partial \theta_{ij}} = \frac{-k e^{-k(X_i w_{ij} - \theta_{ij})}}{(1 + e^{-k(X_i w_{ij} - \theta_{ij})})^2} \dots\dots\dots (19)$$

以上の計算により、修正量 Δw_{ij} 、 $\Delta \theta_{ij}$ が求まり、接続関数の接続パラメータ w と θ の更新は次のように行う。

$$w_{ij}(t+1) = w_{ij}(t) + \Delta w_{ij}(t) \dots\dots\dots (20)$$

$$\theta_{ij}(t+1) = \theta_{ij}(t) + \Delta \theta_{ij}(t) \dots\dots\dots (21)$$

ただし、 $w_{ij}(t+1)$ 、 $\theta_{ij}(t+1)$ は修正後の w_{ij} 、 θ_{ij} の値、 $w_{ij}(t)$ 、 $\theta_{ij}(t)$ は修正前の w_{ij} 、 θ_{ij} の値とする。

5. シミュレーション結果

本論文では、提案した学習アルゴリズムをニューロンモデルに適用し学習性についてのシミュレーションを行った。

まず、4入力の場合で学習可能であることを検証する。学習が行なわれるのはシナプス部の重みと閾値である。学習

表 2 教師信号

Table 2. Teacher's signal

$X_1 X_2 X_3 X_4$	00	01	11	10
00		1		
01	1	1	1	1
11		1		
10		1

図 9 学習前のシナプス結合 (a) と学習後のシナプス結合 (b)

Fig. 9. The network for the Table 2 :before training(a) and after training(b)

図 10 誤差結果

Fig. 10. Learning performance for the problem of Table 2

のアルゴリズムは式 (10) から式 (21) による。また、学習パラメータは表 1とする。

まず、学習の教師信号として表 2のものを用いる。初期設定として、樹状突起に接続するシナプスの初期状態を図 9(a)に示す。また、細胞体の閾値 (θ_{soma})を 0.5、樹状突起から細胞体への重み (w_{soma_j})を 1に設定した。この設定より、SOMA 層は OR の働きをするようになる。以下すべての細胞体の閾値は同じである。また、樹状突起に接続するシナプスの初期状態、つまり、接続層の接続関数パラメータ w と θ は-2から、2の範囲のランダムな値とする。ただし、接続関数パラメータ w と θ の関係は、前節で述べた興奮性シナプス結合か、抑制性シナプス結合かのどちらかの状態にする。また、初期設定の AND の数は 8 個とする。そのような初期設定から学習が行なわれ、正解に近づいているかその結果を誤差変化により表す。その結果を図 10に

表 3 4 入力の教師信号 EX-OR

Table 3. Truth table of the exclusive-OR problem (input=4)

X_4	X_3	00	01	11	10
00			1		1
01	1			1	
11		1			1
10	1			1

図 11 学習前のシナプス結合 (a) と学習後のシナプス結合 (b) と学習後のシナプス結合と一致する神経細胞 (c) (4 入力の EX-OR)

Fig. 11. The network for the exclusive-OR problem (input=4) :before training(a) and after training(b) and its corresponding dendritic tree(c)

示す。結果から、学習は正しく行われていることがわかる。また、学習後のシナプス結合を図 9(b) に示す。

次に、学習の教師信号は線形分離不可能な問題の代表的な例である EX-OR (表 3) を用いる。初期設定として、図 11(a) に示す。また、学習パラメータは以前と同じものである。初期設定の AND の数は 16 個とする。そのような初期設定から学習を行った。図 12 は、その学習のシミュレーション結果であり、学習後のシナプス結合を図 11(b) に示す。シミュレーション結果より、従来では線形分離不

図 12 4 入力の EX-OR における誤差結果

Fig. 12. Learning performance for 4-input exclusive-OR problem

可能 (ここでは、EX-OR) な問題に対して、多層のニューラルネットワークが必要とされたが、この提案したモデルは、線形分離できない EX-OR を 1 層のニューロンで学習可能である。それが生理的実験結果と一致していることを示唆する。

更に、接続関数パラメータ w と θ の学習の結果、樹状突起上のどこに、どのようなシナプス結合が必要か学習により得ることができる。そこで、接続関数パラメータ w と θ の学習の結果、樹状突起の形状がどのように得られるか検証する。表 3 の教師信号の学習結果から得られた学習後のシナプス結合 (図 11(b)) を参考にする。初期状態 (図 11(a)) では 16 本の樹状突起にシナプス結合していたが、学習後には樹状突起の数が 9 本になった。必要なシナプス結合のみが残り、他の不要な結合はなくてもこの細胞体の情報処理に影響がない。不要なシナプス結合がなくなること、また、樹状突起の形状も学習とともに変化することを工学的に示した。更に、本モデルは学習の結果から理想化した神経細胞に置き換えることができる。例えば、学習後のシナプス結合図 11(b) から、図 11(c) のような樹状突起が 4 本、その中の 2 本の樹状突起にはそれぞれ 2 本と 4 本の枝を持つような樹状突起の形状を持つ神経細胞が推測される。また、シナプス結合の位置や、種類などの詳しい構造をも推測することができる。このことが、生理学者にとって樹状突起全体の機能を知る上で有益であることを期待している。

6. ま と め

本論文では、従来のニューロンモデルにおいて、線形荷重和の機能としか考慮されていなかった樹状突起の機能を取り入れ、高度な情報処理を行うものとして新たなニューロンモデルを提案した。網膜神経節細胞における樹状突起に存在するスイッチ作用型の抑制シナプス結合による非線形相互作用を論理関数の AND, OR, NOT を用いて表した。また、その相互作用を一般化して、AND-SOMA の論理的な構成によって表現できるニューロンモデルを提案した。提案したモデルは論理回路の AND-SOMA で構成で

きるのでハードウェア化にも適すると言える。更に、提案したニューロンモデルは学習可能で、その学習性に対してバックプロパゲーションの学習則を用いてシミュレーションを行なった。シミュレーション結果により、本論文で提案したモデルは学習可能であることが確認された。1層のニューロンだけでも、線形分離不可能な問題に対応でき、従来の MuCulloch & Pitts モデルより生体情報処理に忠実であることを言える。また、シミュレーションによりシナプス結合の学習によって不必要なシナプス結合がなくなること、加えて、不必要な樹状突起の枝が退縮することを工学的に示した。さらに、このモデルは学習によってその学習パターンを満たすためには樹状突起上のどこに興奮性シナプス結合が必要で、どこに抑制性シナプス結合が必要か判別可能である。このことが、生体内のそれに対応する機構が発見されるのを促すという構成的研究も期待でき、生体内の生理学者にとって有益なものとなることを期待する。

(平成11年06月28日受付, 同11年12月10日再受付)

文 献

- (1) S.R.Cajal, Histologie du Systeme Nerveux de L'homme oet des Vertebres, T.2, Paris: Maloin, 1911
- (2) 伊藤 正男, ニューロンの生理学, 岩波書店, 1972
- (3) 伊藤 正男, 脳の設計図, 中央公論社, 1980
- (4) W.S.MuCulloch and W.Pitts, "A logical calculus of the ideas immanent in nervous activity", Bull. Math. Biophysics, No.5, pp.115-133, 1943
- (5) 狩野 方伸, "シナプス伝達の可塑性と情報統合", 現代化学, pp34-42, 1997年7月
- (6) C. Koch, T. Poggio and V. Torre, "A Functional Interpretation Of Dendritic Morphology", Phil. Trans. R. Soc. Lond. B 298, 227-264
- (7) B.B.Boycott and H.Wassle, "The morphological types of ganglion cells of domestic cat's retina", J. Physiol, Lond. 240, pp.397-419, 1974
- (8) B.B.Boycott, L.Peichl and H.Wassle, "Morphological types of horizontal cell in the retina of the domestic cat", Proc. R. Soc. Lond. B203, pp229-245, 1978
- (9) B.G.Cleland and W.R.Levick, "Properties of rarely encountered types of ganglion cells in cat's retina and overall classification", J. Physiol, Lond. 240, pp457-492, 1974
- (10) 唐 政, 倉津 誠, 田村 宏樹, 石塚 興彦, 淡野 公一, "樹状突起のメカニズムに基づくニューロンモデル", 電子情報通信学会学会論文誌 A, 2000(採録決定)
- (11) 中野 啓 編著, "ニューロコンピュータの基礎", コロナ社
- (12) 日本物理学会 編/松本 元 責任担当 "脳・心・コンピュータ" 丸善株式会社, 1996
- (13) 北嶋 龍雄, 原 健一, "神経細胞の双極形モデル-シナプス膜の動特性-", 電子情報通信学会学会論文誌 D Vol. J70-D No.4 pp818-826(1987年4月)
- (14) Z. Tang, O. Ishizuka, M. Kuratsu and K. Tanno: "Binary learning machine using back-propagation Technique"-invited paper, Proc. IEEE International Conference on Systems, Man and Cybernetics, San Diego, USA, TP7.6, Oct., 1998.

唐

政 (非会員) 昭57 浙江大・工・電子卒, 昭63 清華大博士課程了. 同年同大・工・微電子学研究所講師. 平1 宮崎大研究生. 平2 同大・工・電子工学科助手. 平5 同大・工・電気電子工学科助教授. 平12 富山大・工・知能情報工学科教授, 現在に至る. 知能情報処理システム, ニューラルネットワーク, 知的 VLSI 回路及びシステム等の研究に従事. IEEE 会員. 工博.

田村 宏樹

(非会員) 平10 宮崎大・工・電気電子卒, 同年同大大学院修士課程入学, 現在に至る. ニューラルネットワークの研究に従事.

石塚 興彦

(非会員) 昭39 鹿児島大・工・電気卒, 昭44 九州大学大学院博士課程単位取得退学. 同年宮崎大・工・助教授, 昭58 同教授, 現在に至る. この間, 多値しきい値回路網, 多値論理回路, ファジー高速アナログ回路, ニューラルネットワークの構成などの研究に従事. 工博.

淡野 公一

(非会員) 平2 宮崎大・工・電子卒, 平4 同大大学院修士課程了. 同年(株)日立製作所マイクロエレクトロニクス機器開発研究所入所. 平5 宮崎大・工・電気電子工学科助手, 現在に至る. ファジーコントローラ, MOS アナログ回路の研究に従事.