

修士論文

スパイキングニューラルネットワークによる
連想記憶モジュールと
デジタルコンピュータ間のインターフェース

平成 31 年 1 月 31 日提出

指導教員 河野 崇 教授

東京大学大学院工学系研究科
電気系工学専攻

学籍番号 37-176462

氏名 豊島 尚樹

概要

スパイクングニューラルネットワークとは、ニューロン (神経細胞) とその接続部であるシナプスから構成される生体の神経ネットワークの電気生理学的な挙動を模倣する数理モデルである。このモデルでは生体で用いられる方式に倣い、情報はニューロンの膜電位の変化およびそれに伴う発火パターンとして表現される。スパイクングニューラルネットワークの並列分散的な性質は電子回路への実装と非常に相性が良く、神経活動を模した情報処理を高速かつ非常に低い消費電力で実行することが可能である。シリコン神経ネットワークと呼ばれるこのような電子回路は次世代の情報処理基盤として期待されており、それぞれニューロンおよびシナプスの活動を模倣するシリコンニューロン回路、シリコンシナプス回路を多数接続することで構成される。

スパイクングニューラルネットワーク上で実行できる処理の 1 つとして、分散的な記憶方式である連想記憶がある。これは脳の海馬と呼ばれる領域における記憶様式を模したものであり、ネットワーク上にいくつかのパターンを事前に記憶させ、不完全なパターンを手掛かりにしてそのうちの 1 つを後から想起することができる。ただし、想起された結果は上記のように生体特有の方法によって表現されている。

よって、スパイクングニューラルネットワークを用いた連想記憶を実行し、その想起結果をデジタルコンピュータとの間でやり取りする電子回路モジュールを作成するためには、生体特有の表現を解釈し、デジタルコンピュータで扱える表現に変換するためのインターフェースが必要となる。これを行うには様々な方法が考えられるが、上記のようにシリコン神経ネットワークは低消費電力であり、今後もさらに低消費電力化が進んでいくことが期待されるため、本研究では、回路モジュール全体の消費電力を低く抑えるためにこのようなインターフェースの部分をも追加のシリコン神経ネットワークとして実装するための種々の手法を提案する。

目次

1	序論	2
1.1	ニューロン	2
1.2	シナプス	2
1.3	スパイクングニューラルネットワークおよびシリコン神経ネットワーク	4
1.4	論文の構成	5
2	本研究で用いるモデル	5
2.1	DSSN(Digital Spiking Silicon Neuron) モデル	5
2.2	シナプスのモデル	11
2.3	連想記憶	12
2.4	ヘブ学習	19
3	本研究の目的	26
4	提案手法	27
4.1	dummy neuron	27
4.2	center neuron と reference neuron	32
4.3	同期度を高めるネットワーク	35
4.4	想起に失敗するケースの分類	39
4.4.1	タイプ1の「望ましくない定常状態」	40
4.4.2	タイプ2の「望ましくない定常状態」	43
4.5	「望ましくない定常状態」を検出する手法	46
4.5.1	発火周期の違いに着目した手法	47
4.5.2	刺激入力 I_{stim} の波形に着目した手法	53
5	結論	55
	謝辞	57
	参考文献	58
	発表文献	59
	付録 A 各種パラメータの値	60

1 序論

1.1 ニューロン

人間の脳は 1000 億個以上のニューロンと呼ばれる神経細胞が相互に接続したネットワークである。個々のニューロンは図 1 に示されているように、主に樹状突起、細胞体、軸索という 3 つの部分からなる構造をしている。このようなニューロンからなる脳の神経ネットワークにおいて、情報は Na^+ , K^+ , Ca^{2+} などの各種イオンの移動に基づいた電気信号として表現・伝達されている [1, 2, 3]。ニューロンの細胞膜の内側と外側とではこれらのイオンの濃度が異なっている (例えば K^+ の濃度は細胞内の方が高く、 Na^+ の濃度は細胞外の方が高い) ため、細胞膜を挟んで「膜電位」と呼ばれる電位差 (細胞外電位を基準として測られる) が生じており、より正確に言えばこの膜電位の時間変化によって情報が表現されている。何も入力がない時には、ニューロンの膜電位は「静止膜電位」と呼ばれる -70mV 程度の値に保たれている (静止状態) が、上記の樹状突起に存在するシナプス結合を通して他のニューロンからの入力を受け取ると、膜電位の値は静止膜電位から変動する。膜電位の値を増加 (脱分極) させるような入力は興奮性の入力、減少 (過分極) させるような入力は抑制性の入力と呼ばれる。各ニューロンは多数の他のニューロンとの間にシナプス結合を持っており、多数のニューロンからの入力の時空間的な総和がある閾値を越えて膜電位を増加させると、膜電位はそのまま急激に上昇し、図 1 に示されるような幅 1ms 程度のパルス状の膜電位の波形が発生する。「活動電位」あるいは「神経スパイク」と呼ばれるこのパルス状の波形は軸索を伝搬し、軸索末端に存在するシナプス結合を介して他のニューロンに情報を伝達する。このようにニューロンが神経スパイクを発生させることを「発火」と呼ぶ。

ニューロンを定値刺激電流 I_{stim} によって刺激すると、 I_{stim} の値が小さいときにはニューロンは静止状態に留まっているが、 I_{stim} の値がある臨界値を越えるとニューロンは周期発火を開始する。この周期発火の周波数は I_{stim} の値に依存するが、Hodgkin は I_{stim} の値を連続的に増加させていったときの発火周波数の変化の仕方の違いによって、ニューロンの性質を以下のように定性的に 2 種類に分類した [4]。

クラス 1 ある臨界値において、任意にゼロに近い周波数で周期発火が開始するタイプ

クラス 2 ある臨界値において、非ゼロの有限周波数で周期発火が開始するタイプ

図 2 はクラス 1 およびクラス 2 のニューロンにおける、 I_{stim} の値に対する発火周波数の変化の様子を示したものである。クラス 1 では I_{stim} の値の変化に伴って発火周波数は広い範囲の値をとり得るが、クラス 2 では発火周波数のとり得る値は比較的狭い範囲に限られている。このような周波数特性以外にもクラス 1 とクラス 2 のニューロンは様々な性質の違いを持ち、それに応じて脳内の情報処理において異なる役割を担っていると考えられているが、両クラスの違いは後述のようにニューロンの挙動を数理モデルとして表現した時の、周期発火が開始する数理的なメカニズムの違いとして説明することが可能である [5]。

1.2 シナプス

シナプスとはニューロンどうしの接続部位であり、化学シナプスと電気シナプスの 2 種類に大別されるが、脊椎動物の脳において主要なのは化学シナプスである [1]。シナプスを通して入力を送る側のニューロンをシナプス前ニューロン、入力を受け取る側のニューロンをシナプス後ニューロンと呼ぶが、化学シナプスにおいては、シナプス前ニューロンの軸索末端がシナプス後ニューロンの樹状突起 (あるいは細胞体) との間に非常に狭い隙間 (シナプス間隙と呼ばれる) を挟んで位置している。化学シナプスという名称は、以下のように神




図1 ニューロンの構造と活動電位 (神経スパイク) の波形 [1]




図2 クラス 1(左) とクラス 2(右) のニューロンの周波数特性

経伝達物質と呼ばれる化学物質によって情報が伝達されることに由来している。まず、シナプス前ニューロンが発火して神経スパイクが軸索末端まで到達すると、電位の上昇を検知してシナプス小胞と呼ばれる袋状の構造が開き、その中に入っていた神経伝達物質がシナプス間隙に向けて放出される。その後、シナプス後ニューロン側に到達した神経伝達物質は特定の受容体と結合し、直接的あるいは間接的に特定のイオンチャネルのコンダクタンス (イオンの通りやすさ) を変化させる。これにより、シナプス後ニューロン側にイオン電流 (シナプス電流と呼ばれる) が流れてその膜電位を変化させ、情報が伝達されることになる。神経伝達物質の放出が終わった後、シナプス電流はゆっくりと減少して 0 に戻る。シナプス伝達によってシナプス後ニューロンの膜電位が増加 (脱分極) する場合には興奮性シナプスと呼ばれ、グルタミン酸などが伝達物質として用いられる。シナプス後ニューロンの膜電位が減少 (過分極) する場合には抑制性シナプスと呼ばれ、GABA などが伝達物質として用いられる。

シナプス前ニューロンからシナプス後ニューロンへどのくらい情報が伝わるかをシナプス伝達効率あるいは結合荷重と呼ぶが、このシナプス伝達効率の値は固定されたものではなく、シナプス前ニューロンおよび後ニューロンの活動などによって変化し得ることが種々の電気生理学実験により示されている (シナプス可

塑性)。適切な方法でシナプス前ニューロンおよび後ニューロンに刺激を与えることで、長期間持続するシナプス伝達効率の値の変化を引き起こすことが可能であり、シナプス伝達効率の値が増加する場合は長期増強、減少する場合は長期抑圧と呼ばれる。これらの長期的な変化は、学習と記憶の神経的な基盤ではないかと考えられている。このような可塑性のルールを一般化したものとして、心理学者の Hebb は 1949 年に「ニューロン A の発火がニューロン B を発火させると、それらの間のシナプス結合が強められる」という仮説を提唱した [6]。この仮説はその後様々な実験によって裏付けられ、今日ではこのようなシナプス前ニューロンと後ニューロンの活動の相関に基づいた学習則 (伝達効率を変化させるルール) は広くヘブ学習と呼ばれている。また、シナプス前ニューロンと後ニューロンの発火時刻の差に基づいて伝達効率に変化する STDP(Spike-Timing Dependent Plasticity)[7] という学習則も知られており、これはヘブ学習を具体化・拡張したものと見ることも可能である。

1.3 スパイクングニューラルネットワークおよびシリコン神経ネットワーク

生体の神経系は、自律性や適応性、ロバスト性などの多くの優れた特性を持ちながら、およそ 20W という非常に低い消費電力で動作する情報処理システムである。昨今のエネルギー問題に基づく電力消費抑制への要求も相まって、このような神経系の優れた特性を受け継ぎ、高度な情報処理を非常に低い消費電力で実行できると期待される神経模倣システムへの注目が高まっている [8]。このような神経模倣システムの中でも特に細かい粒度での模倣を行うシリコン神経ネットワークは、生体の神経ネットワークの電気生理学的な活動をリアルタイムあるいはそれ以上の速度で模倣する電子回路であり、ニューロンの活動を模倣するシリコンニューロン回路を、シナプスの活動を模倣するシリコンシナプス回路によって多数接続することで構成される。現在のところ、シリコン神経ネットワークは画像処理や音声認識、ロボット制御などの他、「構築による解析」の立場から神経系における情報処理原理を解明するための高速シミュレータとしても用いられている。また、生体の神経系と高い互換性を持つことから、損傷した神経組織を補綴する医療デバイスとしての応用に向けても研究されている [9]。シリコンニューロンやシリコンシナプスは具体的には、多くの場合微分方程式として表現されるニューロンやシナプスの数理モデルを解くアナログまたはデジタルの電子回路として実装される。尚、個々のニューロンやシナプスの数理モデルを組み合わせる神経ネットワークの活動を模倣する数理モデルをスパイクングニューラルネットワーク (SNN : Spiking Neuronal Network) と呼ぶため、シリコン神経ネットワークはスパイクングニューラルネットワークを電子回路実装したものであるとも言える。実装される数理モデルの表現能力 (神経活動の再現性の高さ) と計算コストはトレードオフの関係にあり、以下のように用途に応じて使い分けられる。

医療デバイスや高速シミュレータなどのように生体の神経系との互換性が重視される場合には、イオンコンダクタンスモデルと呼ばれる最も複雑なタイプの数理モデルが用いられる [10]。これは膜電位に依存してコンダクタンスが変化する様々なイオンチャネルおよびそこを通過するイオン電流と膜電位の複雑なダイナミクスを詳細に記述したもので、最も有名なものとしてはヤリイカの巨大神経軸索を用いた実験データから得られた Hodgkin-Huxley モデル [11] がある。このタイプのモデルは定量的に非常に正確に神経活動を再現できるが、モデルを構成する微分方程式が複雑なため、回路面積および消費電力がともに大きくなってしまふ。例えば、Hodgkin-Huxley モデルは膜電位を含めた 4 つの変数に関する非線形な微分方程式として表現される。

一方で、大規模なネットワークを低消費電力で実装したいという場合には、積分発火 (I&F) 型のモデルが用いられる。このタイプのモデルは個々の神経スパイクの形状を無視してそのタイミングだけに着目し、膜電位を表す状態変数のリセットとして表現するという大幅な簡略化を行っており、非常にシンプルな微分方程式

として表現される [12]。積分発火型モデルの大規模なネットワークをデジタル回路上に実装した例として最も有名なのが IBM が開発した Truenorth チップ [13] であり、このチップは 100 万個のニューロンと 2 億 5600 万個のシナプスを搭載しながら、わずか 63mW という非常に低い消費電力で動作する。このように積分発火型モデルは低電力化や高集積化に適しているが、そのシンプルさの代償として限られた範囲の神経活動しか再現できない。より広い範囲の神経活動を再現できるよう拡張された積分発火型モデルである Izhikevich モデル [14] など存在するが、やはり神経スパイクを状態変数のリセットで近似していることは変わらず、このように簡略化された部分の特性が脳内の情報処理において重要な役割を果たしている可能性は否定できない。

上記の 2 つのタイプの間位置するのが、定性的ニューロンモデルと呼ばれるタイプのモデルである。分岐解析などの非線形動力学の手法を活用した定性的神経モデリングと呼ばれる手法によって、複雑な微分方程式で表現されるイオンコンダクタンスモデルの背後にある数学的な構造を捉え、それを大幅に歪めることなくより簡略化した新たなモデルを作ることができる。定性的というのは膜電位などの絶対量は扱わないという意味であり、積分発火型モデルのように神経活動の背後にあるメカニズムを無視した簡略化を行うわけではないので、比較的シンプルな微分方程式によって広い範囲の神経活動を再現することが可能である。このタイプのモデルとしては、上記の Hodgkin-Huxley モデルをもとにして導出された FitzHugh-Nagumo モデル [15] が有名である。もとの Hodgkin-Huxley モデルは 4 変数かつ指数関数をモデルの右辺に含むのに対し、FitzHugh-Nagumo モデルは 2 変数でその右辺は多項式として表現される。このように変数を 2 つにまで削減したモデルでは、後の章で (別のモデルを用いて) 述べるように、様々な神経活動の背後にあるメカニズムを両変数で張られる位相平面上で見通し良く解析することが可能である。また、対象とするモデルの数学的構造を多項式ではなく基本的で低電力な回路ブロックの特性曲線の組み合わせによって実現することで様々なタイプの神経活動を低消費電力で再現できる回路が、Kohno らによって提案されている [16]。

1.4 論文の構成

本論文の構成は以下になる。まず、第 2 章では本研究で用いるニューロンとシナプスの数理モデル、および連想記憶の枠組みについて述べる。第 3 章では本研究の目的を述べる。第 4 章ではこの目的に向けたいくつかの提案手法について述べ、最後に第 5 章で結論を述べる。

2 本研究で用いるモデル

2.1 DSSN(Digital Spiking Silicon Neuron) モデル

本研究で用いるニューロンモデルである DSSN(Digital Spiking Silicon Neuron) モデル [17] は、以下のような 2 変数の非線形の微分方程式として表現される。

$$\frac{dv}{dt} = F(v, n) = \frac{\phi}{\tau} (f(v) - n + I_0 + I_{stim}) \quad (1)$$

$$\frac{dn}{dt} = G(v, n) = \frac{1}{\tau} (g(v) - n) \quad (2)$$

$$f(v) = \begin{cases} a_n(v + b_n)^2 - c_n & (v < 0) \\ -a_p(v - b_p)^2 + c_p & (v \geq 0) \end{cases} \quad (3)$$

$$g(v) = \begin{cases} k_n(v - p_n)^2 + q_n & (v < r) \\ k_p(v - p_p)^2 + q_p & (v \geq r) \end{cases} \quad (4)$$

変数 v は膜電位を、 n は抽象化されたイオンチャネルの挙動を表している。このモデルは定性的ニューロンモデルの一種である Morris-Lecar モデル [18] をもとにしてデジタル回路実装向けに最適化されたモデルであり、式 3 や式 4 を区分的な 2 次関数として表現することで多くの回路リソースを消費する乗算の回数を最小限に抑えたり、いくつかのパラメータの値を 2 のべき乗およびそれらの和として表現することで乗算をシフト演算として実行できるようにするなどの工夫がなされている。ある適当なパラメータ設定のもとで、これらの式は v と n で張られる位相平面上に図 3 の左側に示されるようなベクトル場を形成する。図 3 の右側には活動電位 (神経スパイク) の波形の例を示しているが、種々の神経活動を表現するこのような膜電位 v の時間波形は、位相平面上をこのベクトル場に従って移動する状態点 (v, n) の軌道 (図 3 の左側のオレンジ色の曲線) に対応付けられる。図 3 の左側の赤と緑の曲線はナルクラインと呼ばれ、それぞれ $\frac{dv}{dt} = 0$ および $\frac{dn}{dt} = 0$ を満たす点の集合である。2 つのナルクラインの交点では $\frac{dv}{dt} = \frac{dn}{dt} = 0$ が成り立ち、この点から出発した状態点はずっとこの点から動かないため「固定点」と呼ばれる。この図では固定点は 1 点だけ存在し、軌道はこの点に引き寄せられている。これはニューロンの静止状態に対応する。

一般に非線形の微分方程式では解析的に解を求めるのは困難だが、このような固定点の周りで以下のように方程式を線形化することで、その固定点からの摂動が時間とともに増大するのか減衰するのかといった情報を定性的に把握することが可能である (線形安定性解析)[19]。まず (v^*, n^*) が固定点であるとする。つまり、

$$F(v^*, n^*) = 0, \quad G(v^*, n^*) = 0 \quad (5)$$

であるとする。そして、この固定点からの摂動を

$$x = v - v^*, \quad y = n - n^* \quad (6)$$

と表す。この摂動の時間的な挙動を調べるため、まず x に関する微分方程式を求めるのだが、このとき F を固定点の周りでテイラー展開して 2 次以降の高次の項を無視すると、

$$\dot{x} = \dot{v} = F(v^* + x, n^* + y) \approx F(v^*, n^*) + \frac{\partial F}{\partial v}x + \frac{\partial F}{\partial n}y = \frac{\partial F}{\partial v}x + \frac{\partial F}{\partial n}y \quad (7)$$

のようになる (最後の等号は式 5 によるものである)。同様のことを y に関しても行くと、

$$\begin{pmatrix} \dot{x} \\ \dot{y} \end{pmatrix} = \begin{pmatrix} \frac{\partial F}{\partial v}x + \frac{\partial F}{\partial n}y \\ \frac{\partial G}{\partial v}x + \frac{\partial G}{\partial n}y \end{pmatrix} = \begin{pmatrix} \frac{\partial F}{\partial v} & \frac{\partial F}{\partial n} \\ \frac{\partial G}{\partial v} & \frac{\partial G}{\partial n} \end{pmatrix} \begin{pmatrix} x \\ y \end{pmatrix} = A \begin{pmatrix} x \\ y \end{pmatrix} \quad (8)$$

のようになり、 x と y の微分方程式は行列 A で特徴づけられる線形な微分方程式に近似することが可能である。この行列 A を固定点 (v^*, n^*) におけるヤコビ行列と呼ぶ。式 8 をベクトル形式で表すと、

$$\dot{\mathbf{x}} = A\mathbf{x} \quad (9)$$

のようになるが、あるベクトル \mathbf{u} で張られる直線上で指数的に移動する解 $\mathbf{x}(t) = e^{\lambda t}\mathbf{u}$ が式 9 を満たすとなると、これを式 9 に代入することで

$$A\mathbf{u} = \lambda\mathbf{u} \quad (10)$$

が得られるから、 λ はヤコビ行列 A の固有値であり、 \mathbf{u} はそれに対応する固有ベクトルであることが分かる。今、ヤコビ行列 A が相異なる 2 つの固有値 λ_1, λ_2 をもち、それに対応する固有ベクトルがそれぞれ $\mathbf{u}_1, \mathbf{u}_2$ であるとする、上記の観察より $\mathbf{x}(t) = e^{\lambda_1 t}\mathbf{u}_1$ および $\mathbf{x}(t) = e^{\lambda_2 t}\mathbf{u}_2$ は式 9 の解となる。さらにこのとき \mathbf{u}_1 と \mathbf{u}_2 は線形独立となるから、任意の点 \mathbf{x}_0 をこれらの線形結合として $\mathbf{x}_0 = c_1\mathbf{u}_1 + c_2\mathbf{u}_2$ のように書き表すことができる。これらのことから、 $\mathbf{x}(0) = \mathbf{x}_0$ を初期条件とする式 9 の微分方程式の初期値問題の解は、

$$\mathbf{x}(t) = c_1e^{\lambda_1 t}\mathbf{u}_1 + c_2e^{\lambda_2 t}\mathbf{u}_2 \quad (11)$$

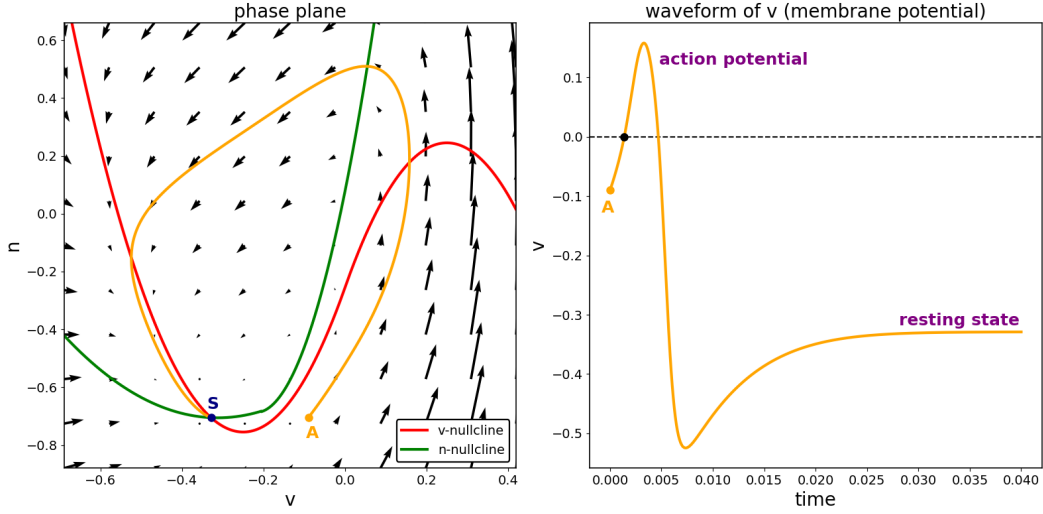


図3 DSSN モデルのベクトル場と軌道の例 (左) および対応する膜電位 v の波形 (右)

となる。なぜなら、直線上を移動する上記の2つの解の線形結合になっており、かつ、初期条件も満たしているからである。さて、ヤコビ行列 A の2つの固有値 λ_1, λ_2 のうち、両方が負の実部をもっていれば、式11の2つの項がどちらも指数的に減衰するため、固定点 (v^*, n^*) からの摂動は時間とともに減衰し、その固定点は安定であると言える。一方で、少なくとも一方の固有値が正の実部をもっていれば、式11で表される固定点からの摂動は指数的に増大するため、その固定点是不安定である。このように、ヤコビ行列の固有値の実部の符号によって、その固定点の安定性を判断することが可能である。DSSN モデルのような2変数の系においては、両方の固有値の実部が負ならその固定点は「安定固定点」、両方ともが正なら「不安定固定点」、正と負が1つずつであれば「鞍点」と呼ばれる。また、固有値が $\lambda = \alpha \pm i\omega$ のように複素数である場合、式11において、

$$e^{\lambda t} = e^{(\alpha \pm i\omega)t} = e^{\alpha t} e^{\pm i\omega t} = e^{\alpha t} (\cos \omega t \pm i \sin \omega t) = e^{\alpha t} \cos \omega t \pm i e^{\alpha t} \sin \omega t \quad (12)$$

となるから、固定点からの摂動は振動しながら減衰あるいは増大し、(もとの非線形な方程式における) その振動の角周波数は固有値の虚部 ω とおおよそ等しくなる。

DSSN モデルは、各種パラメータの値を調整することで、1.1 節で述べたクラス1とクラス2の両方の特性を再現することが可能である。図4の左側は、クラス1のパラメータ設定で定値刺激入力 I_{stim} の値が小さいときの位相平面の様子および2種類の軌道の例を、右側はそれらの軌道に対応する膜電位 v の波形を示している。このとき、2つのナルクラインは3点で交わっており、左から順にそれぞれ安定固定点(図中のS)、鞍点(T)、不安定固定点(U)となっている。状態点が安定固定点にあるときにインパルス状の刺激入力を与えられ、その状態点は位相平面上で瞬間的に水平右方向に押しやられる。状態点はその後ベクトル場に従って移動し、やがて安定固定点に戻ってくるが、このとき軌道のスタート地点が鞍点の安定多様体 ($t \rightarrow \infty$ で鞍点に収束する点の集合) よりも左側であれば、軌道は v と n の大きな上昇を伴わずに安定固定点に戻ってくる(Aの軌道)。一方で、スタート地点が安定多様体の右側であれば、その軌道は鞍点の長い方の不安定多様体 ($t \rightarrow -\infty$ で鞍点に収束する点の集合) の外側を通るため、活動電位(神経スパイク)に相当する v と n の大きな上昇を伴う(Bの軌道)。このように、状態点の変位が鞍点の安定多様体を越えるかどうかが発火の実質的な閾値としての役割を果たしている。

図4の状態から徐々に I_{stim} の値を大きくしていくと、式2より v ナルクラインの位置が上方向にシフトし




図4 定値刺激入力 I_{stim} が小さい時のクラス1の位相平面と軌道の例 (左) および対応する膜電位 v の波形 (右)

ていく。それに伴って安定固定点と鞍点の位置が徐々に近づいていくのだが、ある臨界値において両者は完全に同一の点になり、それ以上に I_{stim} の値を大きくすると消失し、不安定固定点のみが残る。このとき、鞍点の長い方の不安定多様体の両端 (= 安定固定点と鞍点) が接続することで、不安定固定点を囲む安定な周期軌道 (リミットサイクル) が発生する。このようなパラメータ (ここでは I_{stim}) の変化による系の性質の質的な変化を分岐と呼び、このようなタイプの分岐を特に Saddle-Node on Invariant Circle 分岐 (SNIC 分岐) と呼ぶ。図5はそのような大きな I_{stim} のもとでのクラス1の位相平面および軌道の例 (左側) と、それに対応する v の波形 (右側) を示している。ピンク色の閉軌道が上記のリミットサイクルを表しており、その内側から出発した軌道 A も、外側から出発した軌道 B も、最終的にはこのリミットサイクルに引き寄せられている。また右側の図から分かるように、リミットサイクルはニューロンの周期発火に対応している。図6は、SNIC 分岐の直後のリミットサイクル (左側) およびそれに対応する v の波形 (右側) を示している。分岐の直後には、リミットサイクルは図中にオレンジ色で示されるように v ナルクラインと n ナルクラインのどちらにも非常に近い領域を通過する。この領域では $\frac{dv}{dt}$ も $\frac{dn}{dt}$ も非常に小さな値をとるため、ここを通過するには長い時間を要し、結果として分岐の瞬間に近づくほど発火周期は長く (発火周波数は低く) なる。これが、クラス1の周波数特性が発生するメカニズムである。実際、右側に示されている約1周期分の波形において、上記の領域を通過しているオレンジ色の部分がほとんどの時間を占めている。図7はクラス1のDSSNモデルの分岐図と呼ばれる図であり、 I_{stim} の値を分岐パラメータとして変化させながら、それぞれの I_{stim} の値における固定点や周期軌道 (の両端) の v の値をプロットしたものである。図中の I_{snic} と書かれた部分で SNIC 分岐が起こり、安定固定点と鞍点が対消滅して安定周期軌道が発生している。

一方で、図8は I_{stim} の値が小さいときのクラス2の位相平面の様子と軌道の例 (左側)、およびそれに対応する v の波形 (右側) を示している。クラス2のパラメータ設定のもとでは、2つのナルクラインの交点の数は I_{stim} の値に関わらず常に1つであり、 I_{stim} の値が小さいときにはこの交点は安定固定点となっている。よって、位相平面上の軌道は最終的にこの安定固定点に収束するのだが、この固定点におけるヤコビ行列の固有値が複素数になっているため、軌道は回転しながら収束し、それに対応して膜電位 v の波形は減衰振動を示す。また、上記のクラス1のときと違って発火の明確な閾値となるような機構が存在しないため、インパルス状の刺激入力への応答の大きさは刺激の強さに応じて連続的に変化する。

図8の状態から I_{stim} の値を徐々に大きくしていくと、上述のように固定点が消滅することはないが、ある臨界値において (それまで安定であった) 固定点が不安定化し、固定点にあった状態点はその周りに存在す

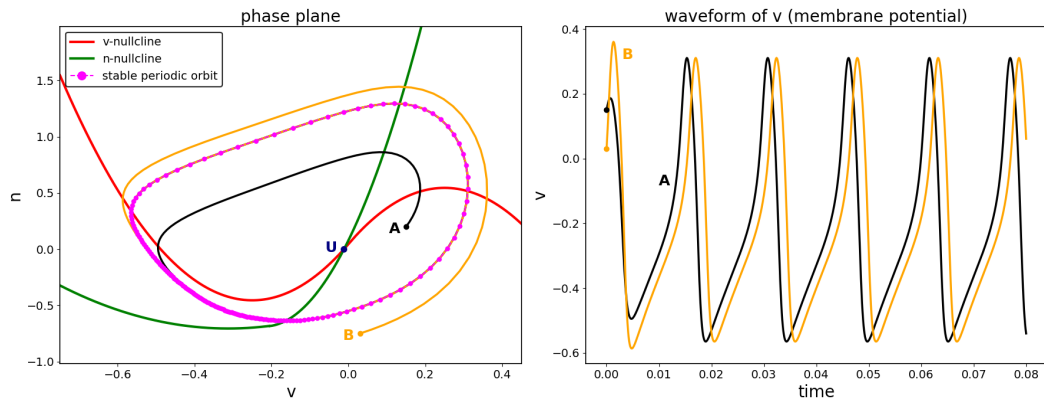


図5 定値刺激入力 I_{stim} が大きい時のクラス1の位相平面と軌道の例 (左) および対応する膜電位 v の波形 (右)

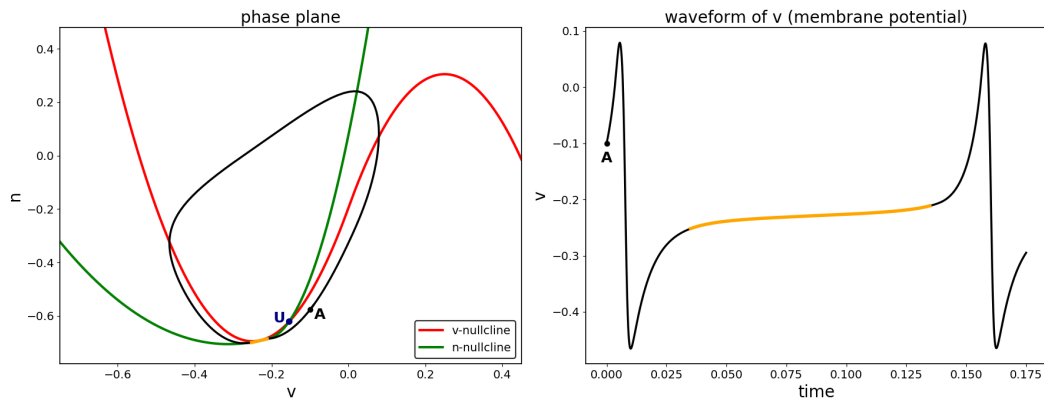


図6 クラス1の周波数特性が発生するメカニズム




図7 クラス1のDSSNモデルの分岐図

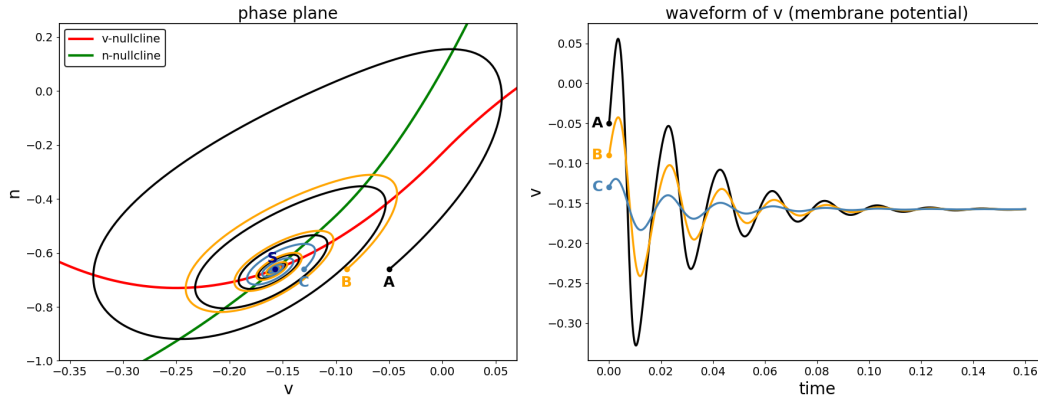


図8 定値刺激入力 I_{stim} が小さい時のクラス2の位相平面と軌道の例 (左) および対応する膜電位 v の波形 (右)




図9 クラス2のDSSNモデルの分岐図

る安定な周期軌道に引き寄せられる。このような分岐を Hopf 分岐と呼ぶ。図9は、クラス2のDSSNモデルの分岐図である。図中の I_{hopf} と書かれた部分で Hopf 分岐が起こり固定点が不安定化しているが、この瞬間に青色で示される不安定周期軌道が固定点にぶつかっていることが分かる。この不安定周期軌道は、 I_{stim} の値が I_{hopf} よりも少し小さい I_{fold} であるときに起こった Fold 分岐という分岐によって、その外側の安定周期軌道と同時に発生したものである。また、 I_{stim} の値が I_{fold} と I_{hopf} の間にあるときには安定固定点と安定周期軌道が共存し、それらが不安定周期軌道によって隔てられていることが分かる。このような状態を bistability(双安定)と呼ぶ。図10は bistability の状態にあるクラス2の位相平面の様子と軌道の例 (上段) およびそれに対応する v の波形 (下段) を表している。ピンク色で示される安定周期軌道の外側から出発した軌道Aはこの安定周期軌道に引き寄せられているのに対し、青色で示される不安定周期軌道の内側から出発した軌道Bは内側にある安定固定点に向かって減衰振動しており、不安定周期軌道の外側と内側のどちらから出発したかによってその状態点が2つの安定状態のどちらに向かうかが決まっている。このようにクラス2においては、上述のクラス1のように分岐直後の発火周波数を抑制する機構は存在しないため、非ゼロの周波数で周期発火が開始する。




図 10 クラス 2 における bistability

2.2 シナプスのモデル

$$\frac{dI_s}{dt} = \begin{cases} \alpha(1 - I_s) & (v > 0) \\ -\beta I_s & (v \leq 0) \end{cases} \quad (13)$$

本研究で用いるシナプスのモデルは、化学シナプスにおける神経伝達物質の放出とイオン電流のダイナミクスを記述した kinetic synapse model[20] をもとにして簡略化を行った Li らのモデル [21] であり、式 13 のようにシナプス電流 I_s に関する微分方程式として表現される。それぞれのニューロンがこの変数 I_s をもっており、刺激入力を受けて膜電位 v が閾値 0 を越える (= 発火する) と I_s は増加を開始し、 v が再び閾値 0 を下回ると減少を開始する。正のパラメータ α および β の値がシナプス電流 I_s の増加および減少の速さを決めており、[21] では $\alpha = 83.3, \beta = 333.3$ という値が用いられているが、これらの値は目的に応じて適宜調節される。図 11 は定値刺激入力によって周期発火するニューロンにおける、膜電位 v とそれに対応するシナプス電流 I_s の波形の例を示している。N 個の DSSN モデルのニューロンが全結合型のネットワークを構成している場合、 i 番目のニューロンにおける刺激入力 I_{stim}^i は以下の式によって計算される。

$$I_{stim}^i = c \sum_{j=1}^N W_{i,j} I_s^j + I_{ext}^i \quad (14)$$

$W_{i,j}$ は j 番目のニューロンから i 番目のニューロンへの結合荷重 (正なら興奮性の結合、負なら抑制性の結合)、 I_s^j は (式 13 に従って変化する) j 番目のニューロンのシナプス電流であり、第 1 項は他のニューロンからのシナプス電流の荷重和を表している (c は電流値のスケールを調節するための正のパラメータである)。一方で、第 2 項の I_{ext}^i は実験者によって与えられる i 番目のニューロンへの外部入力を表している。




図 11 膜電位 v (上段) とそれに対応するシナプス電流 I_s (下段) の波形の例

2.3 連想記憶

連想記憶とはニューラルネットワーク上での分散的な記憶様式であり、脳の海馬と呼ばれる領域における記憶方式を抽象化したモデルである。より具体的には、まず、いくつかのパターン (ベクトル) が事前にニューラルネットワーク上に格納 (記憶) される。以下、これらの格納されたパターンのことを銘記パターンと呼ぶ。その後、ネットワークに何らかのパターンを入力すると、(良い条件のもとでは、) 事前に格納された銘記パターンの中で入力されたパターンに最も近いものがネットワークのダイナミクスにより想起される。連想記憶に用いるネットワークは、人工ニューラルネットワーク (ANN : Artificial Neural Network) でも SNN でもよく、どちらに関しても研究が行われている。

本研究においては、上述の DSSN モデルのネットワーク上での連想記憶 [21] を取り扱う。記憶させるパターンとしては、各要素が $+1/-1$ のどちらかの値をとるような 2 値のパターンを考える。特に本研究では、これ以降に、図 12 に示される長さ (要素数) が 256 のパターン 4 つの組を銘記パターンセットとして用いることとする。この図では分かりやすさのため、 $+1$ の要素を黒色に、 -1 の要素を白色に対応させることで各パターンを白黒の 16×16 ピクセルの画像として表している。パターン上の要素のインデックスとそれを画像として表現したときのピクセルの位置は、図 13 のような対応関係になっている。このような白黒の画像としての表現方法は、これ以降しばしば用いられる。尚、図 12 の銘記パターンセット中の任意の 2 つのパターンの組は、全て互いに直交している (内積をとると 0 になる)。この銘記パターンセットを、同じく 256 ニューロンの DSSN モデルの全結合型のネットワークに記憶させる。ここで、ネットワーク中の各ニューロンは、2 値パターン中の対応する 1 つの要素の値を表現する。つまり、銘記パターンのどれかが正しく想起されたとき、各ニューロンは対応する要素の値が $+1/-1$ のどちらであるかを表現することになる。このように 2 値パターン中の要素とニューロンは 1 対 1 に対応するので、これ以降では、2 値パターン中の i 番目の要素に対応するニューロンのことを、 i 番目のニューロン (あるいはニューロン i) と呼ぶこととする。

連想記憶ネットワークにおける学習とは、記憶させたい銘記パターンセットの情報に基づいて、ネットワーク中のニューロン間の結合荷重を適切に決定することである。これには様々な方法が提案されているが、よく




図 12 本研究で用いる銘記パターンセット




図 13 パターン上の要素のインデックスと、画像として表現したときのピクセルの位置との対応関係

用いられる方法として相関学習 [22] と呼ばれる方法がある。この方法では、 j 番目のニューロンから i 番目のニューロンへの結合荷重 W_{ij} を、以下の式によって静的に決定する。

$$W_{ij} = \begin{cases} \frac{1}{p} \sum_{u=1}^p x_i^u x_j^u & (\text{when } i \neq j) \\ 0 & (\text{when } i = j) \end{cases} \quad (p = 4, 1 \leq i, j \leq 256) \quad (15)$$

ここで、 x_i^u は u 番目の銘記パターンにおける i 番目の要素の値 (+1/-1) を、 p は銘記パターンの数 (本研究では $p = 4$) を表す。このような静的な学習方法の他に、生物学的に妥当性のあるヘブ学習に基づいて動的に結合荷重を更新していく手法なども提案されている [23]。これについては次節で詳しく述べる。

このようにして学習したネットワークが正しく動作するかを検証するには、銘記パターンのどれか 1 つをベースとして、そこにある割合のエラーを入れることで入力パターンを作成すればよい。銘記パターン 1 に基づいて生成された入力パターンの例を図 14 に示す (図中の数字はエラー率)。例えば左端のエラー率 5% の入力パターンでは、 $256 \times 0.05 = 12.8 \approx 13$ より、銘記パターン 1 をベースとして 13 個のランダムに選んだ要素の値を反転させている。この入力パターンと 4 つの銘記パターンとのハミング距離をとると、それぞれ 13、127、131、119 となり、銘記パターン 1 に最も近くなっている。よって、このパターンを入力として与えたときの連想記憶ネットワークの望ましい挙動は、銘記パターン 1 を想起することである。本研究の銘記パターンセットを用いる限り、エラー率が 30% 程度までであれば、生成された各入力パターンはそのベースとなった銘記パターンにハミング距離の意味で最も近くなる。こうして生成された入力パターンを DSSN モデルで構成された連想記憶ネットワークに実際に与えるには、入力パターン中の +1 の要素に対応するニューロンに対してのみ定値刺激電流を短時間印加する。その後は、各ニューロンが発火し続けるように、全てのニューロンに対して同じ値の定値刺激電流を印加し続ける。




図 14 図 12 の銘記パターン 1 に基づいて生成された入力パターンの例

SNN 上での連想記憶では、事前に記憶させた銘記パターンが正しく想起された状態は、ネットワーク中のニューロン群の同期発火状態として実現される。より具体的に言えば、全てのニューロンの発火周期が揃い、かつ、想起されている銘記パターンにおいて +1 の要素に対応するニューロン群と -1 の要素に対応するニューロン群が (互いに混ざり合うことなく) それぞれ時間的にまとまって交互に発火する定常状態に到達する。このような発火パターンを、これ以降 anti-synchronized な発火パターンと呼ぶこととする。銘記パターン 1 を想起した状態の例を図 15 に示す。この図はラスタプロットと呼ばれ、横軸に時間を、縦軸にニューロンのインデックス (=2 値パターン中の対応する要素のインデックス) をとり、各ニューロンの発火時刻 (膜電位 v が閾値 0 を下から上に越える瞬間) を点で示している。また、各点の色は銘記パターン 1 に基づいて付けられている。この図では、+1 の要素に対応するニューロン群と -1 の要素に対応するニューロン群がそれぞれ、位相の意味でもほぼ完全に同期している。図 15 の状態における、特定の 2 つのニューロンの膜電位 v および刺激入力 I_{stim} の時間波形を示したのが図 16 である。図 15 で想起されている銘記パターン 1 において、上段のニューロン 1 は +1 の要素に、下段のニューロン 17 は -1 の要素に対応している。各ニューロンは、式 14 のように外部から印加される定値刺激電流 I_{ext} (茶色の点線) に他のニューロンからのシナプス電流 I_s の荷重和を足し合わせたものを刺激入力 I_{stim} (茶色の実線) として受け取り、膜電位 v を変化させる。 v がしきい値 0 を越える瞬間が発火時刻であり、図中では点で示されている。上段と下段のどちらにおいても、刺激入力 I_{stim} はそのニューロンが属する方のニューロン群の発火を起点として大きく正方向に振れ、もう一方のニューロン群の発火を起点として大きく負方向に振れていることが分かる。

一方で、発火周期は揃い、+1 の要素と -1 の要素にそれぞれ対応するニューロン群が交互に発火してはいるが、各ニューロン群における位相同期が不完全な定常状態に到達する場合もある。このような例のラスタプロットを図 17 に示す。このような定常状態においても、+1 の要素に対応するニューロン群と -1 の要素に対応するニューロン群は時間的に完全に分離されているので、銘記パターン (この場合は銘記パターン 1) が正しく想起されているとみなすことができる。一般的な傾向として、入力パターンにおけるエラー率が高くなるほど (入力パターンが銘記パターンから離れるほど)、想起に成功した際に図 17 のような不完全な同期状態に到達しやすくなるようである (詳細は後述)。先ほどと同様に、図 17 の状態における特定の 2 つのニューロンの膜電位 v および刺激入力 I_{stim} の時間波形を図 18 に示す。刺激入力 I_{stim} は図 16 と大まかには同様に、そのニューロンが発火する時刻の周辺で正方向に振れ、その逆位相にあたる時刻の周辺で負方向に振れているが、各ニューロン群における位相同期が不完全なために図 16 よりも時間方向に広がったような波形になっている。

各ニューロンのある発火時刻からその次の発火時刻までを 1 周期とみなすことで、時刻 t における j 番目の




図 15 銘記パターン 1 を想起した状態のラスタプロット (同期度が高い場合)




図 16 図 15 の状態における、特定のニューロンの膜電位 v および刺激入力 I_{stim} の波形の例

ニューロンの位相 $\phi_j(t)$ を以下のように定義することができる [24]。

$$\phi_j(t) = 2\pi k + 2\pi \frac{t - t_j^k}{t_j^{k+1} - t_j^k} \quad (t_j^k \leq t \leq t_j^{k+1}) \quad (16)$$

ここで、 t_j^k は j 番目のニューロンの k 回目の発火時刻である。このように定義した各ニューロンの位相 $\phi_j(t)$ を用いることで、ある時刻におけるネットワークの発火状態が全体としてどの程度同期しているかを、以下の PSI(Phase Synchronization Index)[24] という指標により定量化することができる。

$$\text{PSI}(t) = \frac{1}{N} \left| \sum_{j=1}^N \exp(i2\phi_j(t)) \right| \quad (17)$$

N はネットワーク中のニューロン数 (本研究では $N = 256$) である。PSI は 0 から 1 の間の値をとり、全てのニューロンが同相または逆相で完全に同期している状態において最大値 1 をとる。また、同じく位相 $\phi_j(t)$




図 17 銘記パターン 1 を想起した状態のラスタプロット (同期度が低い場合)




図 18 図 17 の状態における、特定のニューロンの膜電位 v および刺激入力 I_{stim} の波形の例

を用いることで、ある時刻におけるネットワークの発火状態が各銘記パターンにどの程度類似しているかを、 $\text{overlap}[25]$ という指標で定量化できる。時刻 t における u 番目の銘記パターンとの overlap を $M_u(t)$ とすると、それは以下の式により定義される。

$$M_u(t) = \frac{1}{N} \left| \sum_{j=1}^N x_j^u \exp(i\phi_j(t)) \right| \quad (18)$$

overlap も 0 から 1 の間の値をとる。図 19 および図 20 に、それぞれ図 15 および図 17 の状態に対応する PSI および各銘記パターンとの overlap の時間変化の様子を示す (どちらも最終的に銘記パターン 1 を想起している)。図 19 では入力パターンを与えてすぐに PSI がほぼ 1 に収束し、また、銘記パターン 1 との overlap が 1 に収束している。これは図 15 の完全な同期状態に対応している。他の銘記パターンとの overlap はほぼ 0 に近い値になっている。定義より、全てのニューロンの位相が一律に同じ値だけシフトしても PSI や overlap の




図 19 銘記パターン 1 が想起された時の PSI と overlap の時間変化 (同期度が高い場合)




図 20 銘記パターン 1 が想起された時の PSI と overlap の時間変化 (同期度が低い場合)

値は変わらないので、図 15 や図 17 のような定常状態に到達すると (全ニューロンの発火周期が揃うと)、PSI や overlap はその後一定値になる。一方で、図 20 では PSI が一旦大きな値をとった後、徐々に減少して最終的に 0.6 付近の値に収束している。銘記パターン 1 との overlap も 1 より少し小さい値に収束し、他の銘記パターンとの overlap も 0.2 から 0.3 程度の値をとっている。とは言ってもやはり銘記パターン 1 との overlap が他の 3 つと比べて明らかに大きく、定常状態においては銘記パターン 1 が想起されているとみなすことができる。

図 21 は、多数の入力パターンを用いて想起を行い、入力パターン中のエラー率ごとに、ネットワークが最終的に到達した定常状態における PSI の値の分布をとったものである。具体的には、10%、20%、30% のそれぞれのエラー率のもとで、4 つの銘記パターンそれぞれをベースとした 100 通りずつの入力パターン (全部で $100 \times 4 \times 3 = 1200$ 通り) を生成し、それをもとに想起を行った。どのエラー率の図においても、PSI の値が 1 の付近と 0.5 の付近に分布の大きな山が見られ、また逆に、それ以外の場所には一切分布していない。1 の付近の山が図 15 の定常状態に対応し、0.5 の付近の山が図 17 の定常状態に対応している。右の図に行くほど 1 付近の山が低く、0.5 付近の山が高くなっていることから、入力パターンにおけるエラー率が高くなるほど、PSI が 0.5 付近の (つまり、図 17 のように同期が不完全な) 定常状態に到達しやすくなることが分かる。だが、ネットワークが図 17 のような定常状態に到達したときの PSI の値は、入力パターン中のエラー率が 10%




図 21 入力パターンのエラー率ごとの、定常状態における PSI の値の分布

だろうが 30% だろうが 0.5 付近で変わることはない。逆にエラー率が 30% でも、(可能性は低い)PSI がほぼ 1 の (つまり、図 15 のような) 定常状態に到達することはあり得る。つまり、定常状態における PSI の値を測っても、それだけをもとに入力パターン中のエラー率を推定することはできないということである。同様に図 22 は、入力パターン中のエラー率ごとに、定常状態における 4 つの銘記パターンそれぞれとの overlap のうちの最大値の分布をとったものである。直感的には入力パターンを生成する際のベースとした銘記パターンとの overlap が 4 つのうちで最大となるのが望ましいが、実際にはエラー率が高くなると他の銘記パターンとの overlap が最大になる (つまり、他の銘記パターンに対応する定常状態に到達する) ことも起こり得る。このような挙動はエラー率が 10% や 20% のときにはほぼ見られないが、30% 程度ではしばしば発生する (実際、図 21 および図 22 の作成に用いたエラー率 30% の 400 通りの入力パターンのうち、83 パターンにおいて他の銘記パターンに対応する定常状態に到達した)。このように、最大の overlap は必ずしも入力パターンのベースとなった銘記パターンとのものとは限らないが、ともかく最大の overlap に着目すると、エラー率に関わらず 1 の付近と 0.9 の付近に分布の大きな山が存在することが分かる。1 付近の山が図 15 の定常状態に、0.9 付近の山が図 17 の定常状態に対応する。先ほど図 21 で見たのと同じように、右の図に行くほど 1 付近の山が低く、0.9 付近の山が高くなっているのが分かる。だが、分布における 2 つの山の位置はエラー率によって変わらないため、やはり定常状態における overlap の値を測っても、それだけをもとに入力パターン中のエラー率を推定することはできない。




図 22 入力パターンのエラー率ごとの、定常状態における最大の overlap の値の分布

2.4 ヘブ学習

上記の相関学習においては、連想記憶ネットワークにパターンを銘記させるためにニューロン間の結合荷重を式 15 に従って静的に決定したが、銘記させたいパターンをネットワークに提示しながらヘブ学習に基づいて動的にニューロン間の結合荷重を更新していくことによっても、相関学習によるものに近い結合荷重を獲得することが可能である。Li らは、DSSN モデルのネットワーク上でヘブ学習を用いて連想記憶の銘記パターンを学習させる具体的な手法を提案した [23]。この研究では、上記と同じく 256 ニューロンの DSSN モデルのネットワーク上で図 12 の 4 つの銘記パターンのセットが学習された。ヘブの学習則をより具体化すると、あるシナプスの結合荷重 (伝達効率) は、それにつながるシナプス前ニューロンおよびシナプス後ニューロンのどちらかが発火するたびに少しずつ更新されていく。そしてその更新量 ΔW は、シナプス前ニューロンとシナプス後ニューロンの最新の発火時刻の差 $\Delta t = t^{pre} - t^{post}$ に依存して決まる。シナプス結合の増強だけでなく、同じく記憶にとって重要な現象であるシナプス結合の抑圧についても考慮すると、 Δt と ΔW との関係式は、

$$\Delta W = A_+ \exp\left(\frac{-|\Delta t|}{\tau_+}\right) - A_- \exp\left(\frac{-|\Delta t|}{\tau_-}\right) \quad (19)$$

と表現される。図 23 は Δt を横軸に、 ΔW を縦軸にとってこの関係を表している。この図から分かるように、 ΔW は Δt に関して左右対称である (Δt の絶対値が ΔW を決める) ので、シナプス前ニューロンと後ニューロンの発火時刻の前後関係は意味を持たない。よって、あるシナプスとその逆方向のシナプスの結合荷重 ($W_{i,j}$ と $W_{j,i}$) は常に同じ値となる。また、発火時刻の差が小さいときには結合荷重は増加するが、やや大きい時刻差では結合荷重は減少する。発火時刻の差がある程度以上大きくなると、結合荷重はほぼ変化しない。

さらに、実際にヘブ則に基づいた学習を行うにあたっては、結合荷重が際限なく増加したり減少したりするのを防いで有限の値の範囲内に収めるために、soft bound あるいは hard bound と呼ばれる制限を与える。Li らの研究では 5 種類の具体的な結合荷重の更新ルールが検証され、そのうち soft bound を用いた L4 というルールと hard bound を用いた L5 というルールで正しく学習が行えたと報告されている。L4 ルールでの




図 23 ヘブ学習で用いられる窓関数

結合荷重の更新式は、

$$\Delta W = \frac{(W_{max} - W)(W - W_{min})}{(W_{max} - W_{min})^2} \left[A_+ \exp\left(\frac{-|\Delta t|}{\tau_+}\right) - A_- \exp\left(\frac{-|\Delta t|}{\tau_-}\right) \right] \quad (20)$$

と表される。角括弧内の部分は上記の式 19 と同じであり、前にかかっている $\frac{(W_{max}-W)(W-W_{min})}{(W_{max}-W_{min})^2}$ の部分が soft bound に相当する。 W は現在の結合荷重であり、その値が最大値 $W_{max}(=1)$ や最小値 $W_{min}(=-1)$ に近づくほど、更新量 ΔW の絶対値を抑制するという効果をもたらす。 W が最大値 W_{max} (最小値 W_{min}) に達すると、その値がそれ以上増加 (減少) することはない、 W は必ず有限の値の範囲内に収まる。一方で、L5 ルールでは、結合荷重は式 19 そのものに従って更新される。そのうえで、全ての結合荷重のうちのどれか 1 つが W_{max} あるいは W_{min} に達した瞬間に、全ての結合荷重の更新を停止する。それ以降に結合荷重が更新されることはない。

Li らの方法では、銘記させたい 4 つのパターンそれぞれに基づいた短いパルス状の刺激入力を、繰り返しネットワークに印加する。これによりネットワーク中のニューロンが発火を起こすので、その発火時刻に応じて上記の更新則 (のどちらか) に従ってニューロン間の結合荷重を更新していく。刺激入力を与える手順は、具体的には以下ようになる。

刺激入力はある一定のタイムスロットごとに切り替えられる。まず最初のタイムスロットでは、銘記パターン 1 に基づいた刺激入力を与える。あるパターンに基づいた刺激入力を与えるとは、そのパターンにおいて +1 の値を持つ要素に対応するニューロンのみに短時間持続するパルス印加するということである。その次のタイムスロットでは、銘記パターン 1 の各要素を反転させたパターンに基づいた刺激入力を与える。つまり、今度は銘記パターン 1 において -1 の値をもつ要素に対応するニューロンのみにパルス印加するということである。この 2 タイムスロット分と同じことを合計で 8 回繰り返す。その後、1 タイムスロット分のインターバル (どのニューロンにもパルス印加しない期間) を設ける。ここまでの合計 17 タイムスロット分をひとまとまりとして、同じことを銘記パターン 2、3、4 に関して繰り返す。ここまできたら、再び銘記パターン 1 に戻って同じことを繰り返す。

図 24 は、上記のように銘記パターンに基づいて刺激入力を与え、L4 および L5 ルールに基づいて結合荷重を更新していったときの結合荷重の推移 (上段)、および関連学習によって静的に決定される結合荷重との差

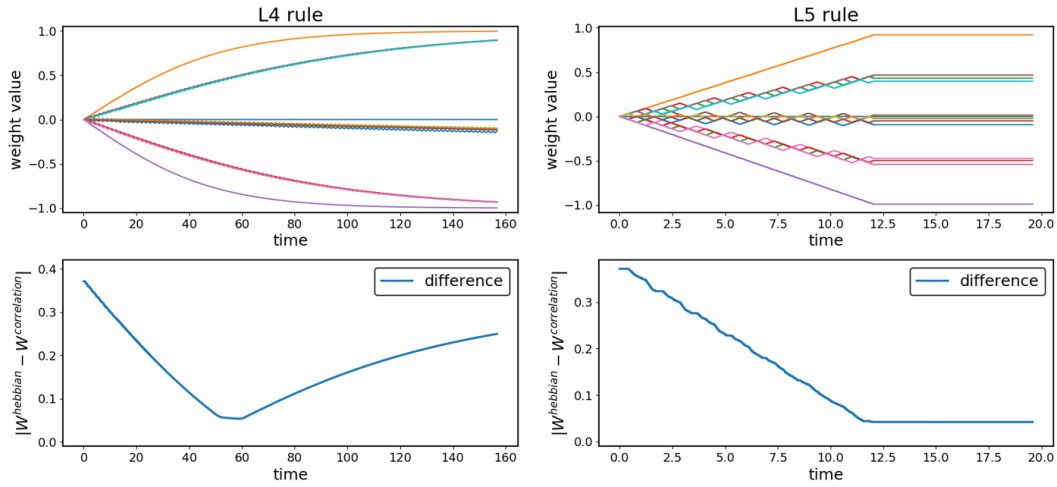


図 24 L4 と L5 ルールによる結合荷重の推移 (上段)、および相関学習による結合荷重との差の推移 (下段)

(の絶対値の平均) の推移 (下段) を示している。L4 ルールでも L5 ルールでも、大まかに同じような結合荷重の推移を示す 5 つのグループが見て取れる。L5 ルールでは、学習開始から 12 秒程度の時点である結合荷重が最小値 $W_{\min} = -1$ に到達し、それに伴って全ての結合荷重の値がそれ以降一定になっている (hard bound)。相関学習による結合荷重との差はおおよそ単調に減少し、最終的に 0.04 程度の値に到達している。L4 ルールでは、学習が進み各結合荷重の絶対値が大きくなるにつれて増加あるいは減少のペースが緩やかになっているのが見て取れる (soft bound)。式 20 で定められる更新量 ΔW の絶対値は次第に小さくなるが、荷重値が W_{\max} あるいは W_{\min} に到達するまでは 0 になることはないので、長時間にわたって学習を行うと多くの結合荷重が +1 または -1 の付近の値に到達してしまっている。相関学習による結合荷重との差は学習開始から 60 秒程度の時点まではおおよそ単調に減少しているが、それ以降はむしろ増加してしまっている。よって、L4 ルールで正しく学習を行うためには、何らかの基準を設定して適切なタイミングで荷重値の更新をストップさせなければならない。図 25 は、L5 ルールのヘブ学習で最終的に得られた結合荷重と相関学習による結合荷重との差 (左図) およびその絶対値 (右図) のヒストグラムである。ヘブ学習による結合荷重は、相関学習による結合荷重のまわりで、やや負側に偏って分布していることが分かる。絶対値の差は最大でも 0.1 程度であり、平均すると 0.04 程度の値となる (これは図 24 の下段右側と対応している)。

以下では L5 ルールに着目し、どのようなメカニズムで学習が進んでいくのかを検証する。図 26 は、ヘブ学習の最中で銘記パターン 1 に関連する刺激入力を与えている 17 タイムスロットにわたるラスタプロットである。図中の Pattern1 は「銘記パターン 1 に基づいたパルスを与えている期間」、 $\overline{\text{Pattern1}}$ は「銘記パターン 1 の反転パターンに基づいたパルスを与えている期間」を示している。また、プロットされた点の色 (黒/白) は銘記パターン 1 に基づいている。各タイムスロットにおいて、パルスを与えられたニューロンのみが位相を揃えて選択的に発火していることが分かる。図 27 は、図 26 と同じ期間における特定のニューロンへの刺激入力 I_{stim} とその膜電位 v の波形を示している。上段のニューロン 1 は銘記パターン 1 において +1 の要素に対応し、下段のニューロン 17 は -1 の要素に対応する。各ニューロンは式 14 のように、紫色の線で示される「銘記パターンに基づいたパルス」とオレンジ色の線で示される「他のニューロンからのシナプス電流の線形和」を足し合わせたものを刺激入力 I_{stim} として受け取り、膜電位 v を変化させる。上段でも下段でも、銘記パターンに基づいたパルスが印加されるたびに膜電位が急激に上昇し、発火を引き起こしている一方で、




図 25 ヘブ学習と相関学習で得られた結合荷重の差の分布




図 26 ヘブ学習期間におけるラスタープロット

他のニューロンからのシナプス電流は各ニューロンの発火にほとんど寄与していないことが分かる。

図 28 は、図 27 に示したニューロン 1 とニューロン 17 の間の結合荷重 $W_{1,17}$ の値の推移を示している。 $W_{1,17}$ は同じような減少・増加を繰り返しながら全体としては増加していき、最終的には 0.398 程度の値に到達している。上段の図の灰色の部分拡大した下段の図を見ると、それぞれの銘記パターンに関連する刺激入力を与えられている期間中では、 $W_{1,17}$ の値は単調に減少、あるいは単調に増加していることが分かる。具体的には、銘記パターン 1 に対応する期間でのみ減少し、銘記パターン 2、3、4 に対応する期間では増加している。また、下段の図中に示した黒または白の丸印は、それぞれの銘記パターンにおいてニューロン 1 およびニューロン 17 に対応する要素が +1 (黒) なのか -1 (白) なのか、を示している。これも併せて見ると、ニューロン 1 とニューロン 17 に対応する要素の値が一致しない (+1 と -1) ような銘記パターンの期間では $W_{1,17}$ は減少し、それらが一致する (+1 と +1、あるいは -1 と -1) ような銘記パターンの期間では $W_{1,17}$ は増加していることが分かる。図 29 は、図 28 と同じ方法で別の結合荷重 $W_{1,56}$ の値の推移を示している。先ほどの $W_{1,17}$




図 27 ヘブ学習期間における、あるニューロンの膜電位 v と刺激入力 I_{stim} の波形の例

と同じく減少と増加が繰り返されているが、この図では減少と増加がおおよそ拮抗し、 $W_{1,56}$ は全体としてはずっと 0 付近の値を推移し続け、最終的に -0.05 程度の値に到達している。下段の詳細な図を見ると、先ほどと同じように、ニューロン 1 とニューロン 56 に対応する要素の値が一致しない銘記パターン 1 および銘記パターン 4 の期間では $W_{1,56}$ は減少し、それらが一致する銘記パターン 2 および銘記パターン 3 の期間では $W_{1,56}$ は増加していることが確認できる。1 つの銘記パターンの期間中に $W_{1,56}$ が減少あるいは増加する量は銘記パターンによらずおおよそ同じであるため、4 つの銘記パターンそれぞれに対応する期間を 1 回ずつ終わると $W_{1,56}$ はほぼ元の値に戻っている。

図 30 は、ニューロン 1 およびニューロン 17 の発火履歴 (ラスタプロット) とそれに伴う結合荷重 $W_{1,17}$ の値の推移を対応づけて示したものである。銘記パターン 1 ではニューロン 1 とニューロン 17 に対応する要素の値が一致しない (+1 と -1) ので、(図 26 にも示したように) 銘記パターン 1 に対応する期間 (左上の図) においてはニューロン 1 とニューロン 17 は交互に発火している。それに伴い、各タイムスロットにおいてどちらかのニューロンが発火するたびに $W_{1,17}$ は一定の値ずつ減少している。どちらのニューロンの発火も各タイムスロット内のほぼ同じ位相で起こっているから、2 ニューロン間の発火の時間差 Δt は常にタイムスロット 1 つ分の長さ Δt_1 と等しく、それに対応して図 23 中の赤い点で示される $\Delta W_{decrease}$ だけ結合荷重は減少する。(尚、銘記パターン切り替え直後の 1 つめのタイムスロットでは、直前のインターバルのタイムスロットの影響で結合荷重の減少量がやや異なる。) 一方で、銘記パターン 2、3、4 ではニューロン 1 とニューロン 17 に対応する要素の値が一致している (+1 と +1、あるいは -1 と -1) ので、これらの銘記パターンに対応する期間では両ニューロンはほぼ同時に発火している。これに伴い、2 タイムスロットに 1 回の頻度で両ニューロンが同時に発火するたびに $W_{1,17}$ は一定の値ずつ増加している。このとき、2 ニューロン間の発火の時間差 Δt は常にほぼ 0 であり、それに対応して図 23 中のオレンジ色の点で示される $\Delta W_{increase}$ だけ結合荷重は増加する。このように、1 つの銘記パターンに対応する期間の中で、減少の場合は 1 タイムスロットごとに、増加




図 28 ある 1 つの結合荷重の推移の例 1

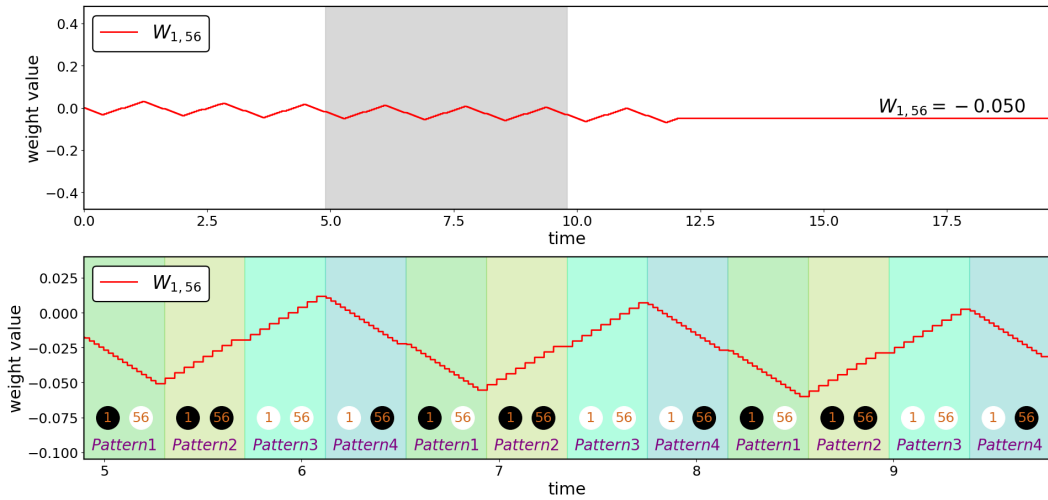


図 29 ある 1 つの結合荷重の推移の例 2

の場合は 2 タイムスロットごとに 1 回の頻度で値の更新が発生するが、 $\Delta W_{decrease}$ の絶対値は $\Delta W_{increase}$ の絶対値のおよそ半分であるため、期間中の総減少量と総増加量は結果的にほぼ等しくなる。

表 1 は、以上のことを踏まえて相関学習と (L5 ルールによる) ヘブ学習との対応関係をまとめたものである。任意の (i, j) の組に対し、 $similarity_{i,j}$ という量を定義する。これは、 i 番目の要素と j 番目の要素の値が一致する (+1 と +1、あるいは -1 と -1) ような銘記パターンの数を表す。定義より、 $similarity_{i,j}$ は 0、1、2、3、4 の 5 種類の値のどれかをとるが、この値によって、表のように対応する結合荷重 $W_{i,j}$ の相関学習およびヘブ学習における振る舞いを分類することができる。まず相関学習の式 15 と $similarity_{i,j}$ の定義から、相関学習での結合荷重 $W_{i,j}$ の値は表のように $similarity_{i,j}$ の値ごとに一意に決まることが分かる。一方で、表の左から 3 列目は、ヘブ学習において 4 つの銘記パターンそれぞれに対応する刺激入力を与える 1 サイクルの間の結合荷重 $W_{i,j}$ の推移の仕方を示している。上で見たように、 i 番目の要素と j 番目の要素の値が一致するような銘記パターンの期間では $W_{i,j}$ の値は増加し、それらが一致しないような銘記パターンの期間では

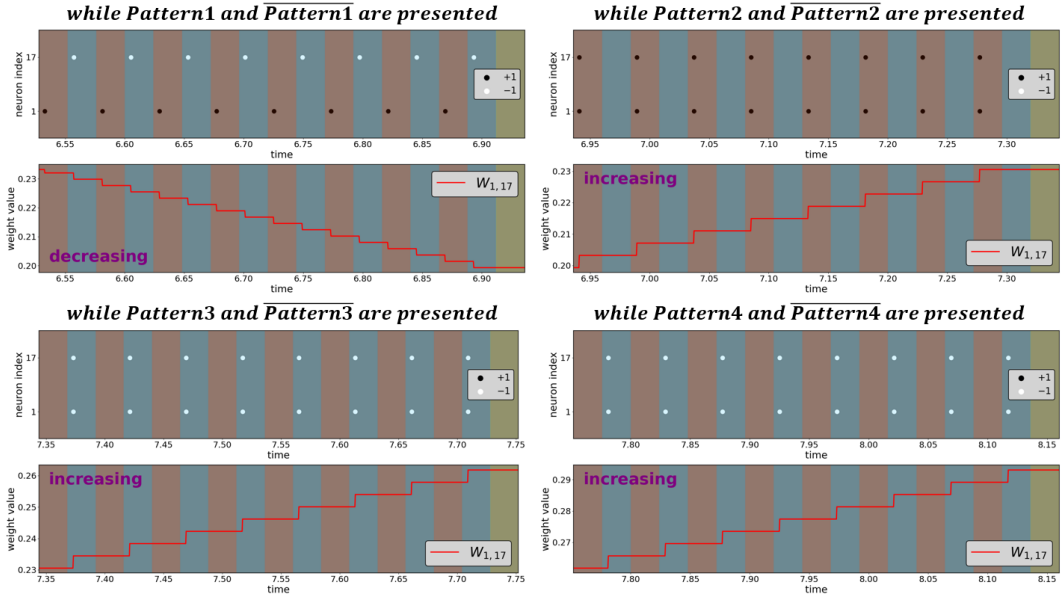
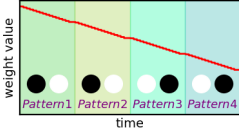
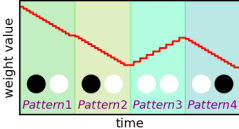
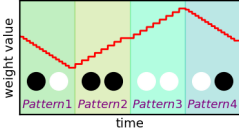
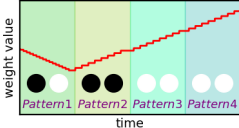
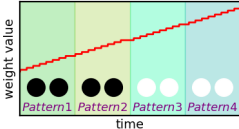


図 30 シナプス前ニューロンおよび後ニューロンの発火の履歴と結合荷重の推移との対応

$W_{i,j}$ の値は減少する。よって、定義より $similarity_{i,j}$ はこの 1 サイクル中で $W_{i,j}$ の値が増加する期間 (つまり銘記パターン) の数と等しく、また 1 つの銘記パターンの期間における減少量および増加量は銘記パターンによらずおよそ一定なので、この 1 サイクルにおける $W_{i,j}$ の正味の変化量は $similarity_{i,j}$ の値ごとにほぼ一意的に決定される。さらに $similarity_{i,j} = 1$ の場合には、4 つの銘記パターンの期間のうちで $W_{i,j}$ の減少量と増加量が 1 期間分ずつほぼ打ち消しあうので、1 サイクルでの正味の減少量は $similarity_{i,j} = 0$ の場合のおよそ半分になり、相関学習による $W_{i,j}$ の符号および絶対値との対応関係が見て取れる ($similarity_{i,j} = 3$ の場合と $similarity_{i,j} = 4$ の場合の関係も同様)。 $similarity_{i,j} = 2$ の場合には $W_{i,j}$ の減少量と増加量が 2 期間分ずつほぼ打ち消しあうので、1 サイクルでの $W_{i,j}$ の正味の変化量はほぼ 0 となり、これも相関学習による結合荷重と対応している。このような 5 種類の $similarity_{i,j}$ の値による結合荷重の推移の仕方の違いは、図 24 の右上段の図にみられる 5 つのグループに対応している。表の右端の列は、ヘブ学習で最終的に得られた結合荷重の $similarity_{i,j}$ の値ごとの平均 $\overline{W_{i,j}}$ およびその標準偏差 σ を示しており、左から 2 列目の相関学習による結合荷重とおおよそ近い値をとっていることが確認できる。

表 1 相関学習とヘブ学習の対応関係

$similarity_{i,j}$	$W_{i,j}$ (correlation)	weight transition in hebbian	$\overline{W_{i,j}}$ (hebbian)
$similarity_{i,j} = 0$	$W_{i,j} = -1$		$\overline{W_{i,j}} = -0.990(\sigma = 0.005)$
$similarity_{i,j} = 1$	$W_{i,j} = -0.5$		$\overline{W_{i,j}} = -0.514(\sigma = 0.028)$
$similarity_{i,j} = 2$	$W_{i,j} = 0$		$\overline{W_{i,j}} = -0.037(\sigma = 0.032)$
$similarity_{i,j} = 3$	$W_{i,j} = 0.5$		$\overline{W_{i,j}} = 0.441(\sigma = 0.029)$
$similarity_{i,j} = 4$	$W_{i,j} = 1$		$\overline{W_{i,j}} = 0.922(\sigma = 0.003)$

3 本研究の目的

本研究の将来的な目的は、SNN 上での連想記憶を実行し、デジタルコンピュータとの間でその入力/出力パターンをやり取りする電子回路モジュールを作成することである。この電子回路モジュールが行う処理は、具体的には以下のような手順を踏む。

1. デジタルコンピュータから 2 値の入力パターンを受け取る。
2. 受け取った入力パターンをもとに SNN 上での連想記憶を実行し、何らかの発火パターンを得る。
3. 得られた発火パターンをもとに、まず想起が成功したかどうかを判断する。
4. 想起が成功していれば、発火パターンを 2 値の出力パターンとして解釈し、それをデジタルコンピュータに返す。
5. 想起が失敗していれば、そのことをデジタルコンピュータに通知する。

この目的に向けて本研究では、上記の手順の 3. から 5. の部分 (デジタルコンピュータとの間のインターフェース) に焦点を当て、大きく分けて 2 つの課題に取り組む。

1. (想起に成功した場合、) 連想記憶の出力として得られる発火パターンの、2 値のパターンへの変換
2. 想起に失敗した場合に発生する現象の調査、およびその検出

1. については前章で述べたように、SNN 上での連想記憶においては、出力はあくまで各ニューロンの膜電位の波形あるいはそれに対応したネットワーク全体での時空間的な発火パターンであり、想起に成功しても 2 値のパターンがそのまま出力されるわけではない。よって、anti-synchronized な状態にある発火パターンを解釈して 2 値の出力パターンに変換する手法を考案する。2. については、前章では想起が成功した時の発火パターンの例を示したが、銘記パターンのどれにもあまり近くないような入力パターンが与えられた時には連想記憶の処理は失敗する可能性が考えられる。そのような場合には上記の手順のようにそれを検出してデジタルコンピュータに通知したいが、SNN 上での連想記憶の処理が失敗した時にどのような現象が発生するのかということはそもそもあまり明らかにされていない。よって、まずはその調査を行い、さらにそれを検出するための手法を考案する。

重要な点として、本研究においては上記の「デジタルコンピュータとの間のインターフェース」部分の処理を、連想記憶の処理を行うもとの SNN から入力信号 (シナプス電流 I_s) を受け取る追加の SNN として実現する手法を考える。これは、回路モジュール全体をシリコン神経ネットワークとして実装することで、消費電力を低く抑えられると期待されるためである。

4 提案手法

まず前章で述べた 2 つの課題のうちの 1 つめに関して、SNN 上での連想記憶の成功時の出力として得られる anti-synchronized な発火パターンを 2 値のパターンに変換しようとする際、第 2 章の図 15 や図 17 では各ニューロンに対して図 12 の銘記パターン 1 に基づいて色を付けて示していたため、銘記パターン 1 に対応した発火パターンになっていることが容易に分かった。しかし、より現実的な状況設定を考えると、どのような銘記パターンがいくつネットワーク上に記憶されているのかは想起の際には分からないはずであり、想起に成功した時の発火パターンは図 31 のように見えるはずである。つまり、天下りのように知っている銘記パターンセットの中のどれを想起しているかという答え合わせをするのではなく、得られた発火パターンだけをもとにして 2 値のパターンへの変換を行う必要があるのである。発火パターンが anti-synchronized な状態になっており、想起が成功していると仮定すると、それを 2 値のパターンに変換するには以下の 2 つの操作を行う必要がある。

1. 交互に発火する 2 つのニューロン群のうち、どちらが +1 の要素に (あるいは -1 の要素に) 対応するのかを判断する。
2. 図 17 のように同期度が低い状態であれば、図 15 のように同期度の高い状態に変換する。

これらのうち、まず 4.1 節で 1 つめの操作について述べ、4.2 および 4.3 節で 2 つめの操作について述べる。次に前章で述べた 2 つの課題のうちの 2 つめに関して、4.4 節で想起に失敗したときに発生する現象の調査結果を、4.5 節で想起の失敗を検出する手法を述べる。

4.1 dummy neuron

上記の 1 つめの操作を行う必要があるのは、銘記パターンに関する事前情報なしに図 31 の発火パターン (実際には図 12 の銘記パターン 1 が想起されている) を見ただけでは、図 32 のどちらにも解釈できてしまうためである。左は正しい銘記パターン 1、右はその各要素 (+1/-1) を反転させたパターンである。この不定性を解消するため、1 つのニューロンをもとの連想記憶ネットワークに追加する。以下、このニューロンを「dummy




図 31 銘記パターンに関する事前情報を持たないと想定した時の発火パターンの見え方

neuron」と呼ぶこととする。具体的な仕組みは以下で述べるが、何らかの銘記パターンが正しく想起されたとき、つまりネットワーク全体の発火パターンが図 15 や図 17 のようになっているとき、dummy neuron は必ず (そのときの入力パターンに依らず) +1 の要素に対応するニューロン群と同期して発火するように設定される。いわば、+1 の要素に対応するニューロン群に dummy neuron でマーカを付けるようなものである。

ここから、dummy neuron が上記のように動作する仕組みを説明する。まず 4 つの銘記パターンそれぞれに対し、図 33 のように、+1 の値を持つ 1 つの「dummy component」を追加する。銘記パターンの長さ (要素数) および対応する連想記憶ネットワークのニューロン数を N (本研究では $N = 256$) とすると、dummy component の追加によって各銘記パターンの長さは $N + 1$ になる。こうしてできた長さ $N + 1$ の銘記パターンのセットを、式 15 の相関学習によって、 $N + 1$ ニューロンのネットワークに記憶させる。このとき、dummy component に対応する $N + 1$ 番目のニューロンが dummy neuron である。銘記パターンの長さが $N + 1$ になったのに合わせ、入力パターンにも同じく +1 の値を持つ 1 つの dummy component を追加する。このような設定の下で入力パターンをネットワークに与え、図 15 や図 17 のような定常的な発火パターンに到達したとき、ネットワークは図 33 に示される長さ $N + 1$ の銘記パターンのうちのどれか 1 つを想起しているはずである。このとき、dummy component の値は全ての銘記パターンにおいて +1 であるので、それに対応する dummy neuron は、どの銘記パターンが想起されていようとも常に +1 を想起している。よって、交互に発火している 2 つのニューロン群のうち、dummy neuron と同期している方のニューロン群が +1 の要素に対応する、と判断できる。

もとの連想記憶ネットワーク中の各ニューロンから dummy neuron への結合荷重 $W_{dummy,i}$ は、相関学習の式 15 に $x_{dummy}^1 = x_{dummy}^2 = x_{dummy}^3 = x_{dummy}^4 = +1$ を代入することで、

$$W_{dummy,i} = \frac{1}{p} \sum_{u=1}^p x_i^u \quad (p = 4, 1 \leq i \leq N = 256) \quad (21)$$

と設定する。また、dummy neuron からもとの連想記憶ネットワーク中の各ニューロンへと戻る方向の結合を持たせてしまうと、もとの連想記憶ネットワークの挙動に変更を加えてしまうことになるので、この方向の




図 32 発火パターンを 2 値パターンとして解釈する際の、反転したパターンに関する不定性




図 33 各銘記パターンに追加される dummy component

結合はすべて 0 とする。つまり、

$$W_{i,dummy} = 0 \quad (1 \leq i \leq N = 256) \quad (22)$$

とする。

dummy neuron を追加したネットワークで正しく銘記パターンが想起されたときのラスタプロットを図 34(同期度が高い場合) および図 35(同期度が低い場合) に示す。dummy neuron の発火時刻は赤い点で示されている。どちらの場合でも、dummy neuron は確かに +1 の要素に対応するニューロン群と同期して発火していることが確認できる。

ここで注意すべきなのは、図 35 のような同期度が低い場合において、dummy neuron は +1 に対応するニューロン群の真ん中あたりの時刻で発火するとは限らず、その端にあたる時刻で発火することもあり得るということである。これに関連して、4 つの銘記パターン全てにおいて +1 であるような要素は図 36 中の黄緑色の点で示すように 16 個存在するが、これらの要素に対応するニューロン群は図 15 や図 17 のような定常状態において、(PSI の値に関わらず) 必ず位相のレベルまで同期しているようである。そしてより詳細にみると、dummy neuron は図 37 のように定常状態においては必ずこのニューロン群と完全に位相を揃えて発火するようである。これは、dummy neuron に対応する dummy component が 4 つの銘記パターン全てにおいて +1 であることと関係していると考えられる。

尚、図 33 において各銘記パターンに追加する dummy component の値を全て -1 に変えれば、それに対応する dummy neuron は -1 の要素に対応するニューロン群と必ず同期して発火する。この場合の dummy neuron




図 34 dummy neuron を含めたラスタプロット (同期度が高い場合)




図 35 dummy neuron を含めたラスタプロット (同期度が低い場合)




図 36 4つの銘記パターン全てにおいて +1 であるような要素




図 37 dummy neuron の挙動の詳細 (同期度が低い場合)




図 38 -1 の要素に対応するニューロン群と同期する dummy neuron を含めたラスタプロット

への結合荷重 $W_{dummy,i}$ は、相関学習の式 15 に $x_{dummy}^1 = x_{dummy}^2 = x_{dummy}^3 = x_{dummy}^4 = -1$ を代入することで、

$$W_{dummy,i} = -\frac{1}{p} \sum_{u=1}^p x_i^u \quad (p=4, 1 \leq i \leq N=256) \quad (23)$$

と設定すればよい。このような dummy neuron を追加したときのラスタプロットは、図 38 のようになる。ピンク色で示された dummy neuron の発火時刻は、確かに-1 の要素に対応するニューロン群と同期しており、さらに図 37 で見たのと同じように、「4 つの銘記パターン全てにおいて-1 であるような要素」に対応するニューロン群 (黄色で示されている) とは位相まで完全に揃っていることが見て取れる。

4.2 center neuron と reference neuron

次節で上記の 2 つめの操作 (同期度の高い状態への変換) について述べるための前準備として、本節では 2 つの特別な役割を持つニューロンを新たにネットワークに追加する。これらのニューロンはもとの連想記憶ネットワーク中の全てのニューロンとの間に結合を持ち、一方的に入力 (シナプス電流 I_s) を受け取る。以下、これらのニューロンをそれぞれ「center neuron」および「reference neuron」と呼ぶ。図 39 および図 40 は、それぞれ図 15 および図 17 の「想起に成功した状態」に対応する、center neuron と reference neuron を加えたラスタプロットである。これらの図に示されているように、想起に成功した状態において、center neuron は「交互に発火する 2 つのニューロン群それぞれの中心ぐらの時刻」に発火し、一方で reference neuron は「交互に発火する 2 つのニューロン群の間に存在する、どのニューロンも発火しない空白期間」に発火するように設定される。

ここからは、まず center neuron がこのように動作する仕組みについて説明する。「交互に発火する 2 つのニューロン群それぞれの中心ぐらの時刻」に center neuron を発火させるためには、適切な結合荷重を設定することで「2 つのニューロン群それぞれの中心ぐらの時刻において大きな値をとり、2 つのニューロン群の間の空白期間において小さな値をとる」ような刺激入力 I_{stim} を作り出し、それによって center neuron を刺激すればよい。連想記憶ネットワーク中の各ニューロンは発火すると図 11 のような波形のシナプス電流 I_s を放出する。図 41 の黒色と白色の線は、図 17 のような状態におけるいくつかのニューロンのシナプス電流 I_s の波形を示したものである (黒/白の色はこのとき想起されている銘記パターンに基づいて付けられている)。 $I_s = 0$ の直線上に打たれた点は、それぞれの波形に対応する発火時刻を示している。この波形からも、+1 の要素に対応するニューロン群と -1 の要素に対応するニューロン群が交互に発火している様子が見て取れる。オレンジ色の線はネットワーク中の全ニューロンのシナプス電流の平均をとった波形である。多くのニューロンが集中して発火する期間とどのニューロンも発火しない空白期間が交互に繰り返されるのに対応して、この平均の波形は 2 つのニューロン群それぞれの中心ぐらの時刻 (実際には少し遅れている) で最高値をとり、それらの間の空白期間において最低値をとっているのがわかる。よって、この平均の波形の振幅を適当に調整し、それによって center neuron を刺激すれば、上記のような時刻に発火させることが可能である。つまり、center neuron への刺激入力 I_{stim}^{center} は、

$$I_{stim}^{center} = A \cdot \left(\frac{1}{N} \sum_{i=1}^N I_s^i \right) = \sum_{i=1}^N \left(\frac{A}{N} \right) \cdot I_s^i \quad \left(\because W_{center,i} = \frac{A}{N} \right) \quad (24)$$

のように計算される。正の係数 A は適切に選択される。図 42 のオレンジ色の線は式 24 によって作られる center neuron への刺激入力 I_{stim}^{center} の波形を、ピンク色の線はそれにより刺激された center neuron の膜電位 v の波形を示している。2 つのニューロン群それぞれの中心ぐらの時刻において刺激入力が高値をとるのに応じて膜電位も急上昇し、発火しているのが見て取れる。

reference neuron の動作原理も同じような発想に基づいている。今度は、適切な結合荷重を設定することで「2 つのニューロン群の間の空白期間において大きな値をとり、2 つのニューロン群それぞれの中心ぐらの時刻において小さな値をとる」ような刺激入力 I_{stim} を作り出し、それによって reference neuron を刺激すればよい。図 41 の黄色の線は先ほどのオレンジ色の波形を -1 倍した波形であり、空白期間において最高値をとり、2 つのニューロン群それぞれの中心ぐらの時刻 (実際には少し遅れている) で最低値をとっている。ただし、このままでは常に負の値をとっているため、一定値のバイアス (外部入力) を加え、さらに適切に振幅を




図 39 center neuron および reference neuron を含めたラスタプロット (同期度が高い場合)




図 40 center neuron および reference neuron を含めたラスタプロット (同期度が低い場合)

調整する。つまり、reference neuron への刺激入力 $I_{stim}^{reference}$ は、

$$I_{stim}^{reference} = B \cdot \left(\frac{-1}{N} \sum_{i=1}^N I_s^i \right) + C = \sum_{i=1}^N \left(\frac{-B}{N} \right) \cdot I_s^i + C \quad \left(\because W_{reference,i} = \frac{-B}{N} \right) \quad (25)$$

とすればよい。正の係数 B, C は適切に選択する。図 43 の黄色の線は式 25 によって作られる reference neuron への刺激入力 $I_{stim}^{reference}$ の波形を、紫色の線はそれにより刺激された reference neuron の膜電位 v の波形を示している。空白期間において刺激入力が必要な値をとるのに応じて膜電位も急上昇し、発火しているのが見て取れる。




図 41 連想記憶ネットワーク中の各ニューロンのシナプス電流 I_s およびその平均、-1 倍した平均の波形 (同期度が低い場合)




図 42 連想記憶ネットワーク中の各ニューロンのシナプス電流 I_s 、center neuron への刺激入力 I_{stim} およびその膜電位 v の波形 (同期度が低い場合)




図 43 連想記憶ネットワーク中の各ニューロンのシナプス電流 I_s 、reference neuron への刺激入力 I_{stim} およびその膜電位 v の波形 (同期度が低い場合)

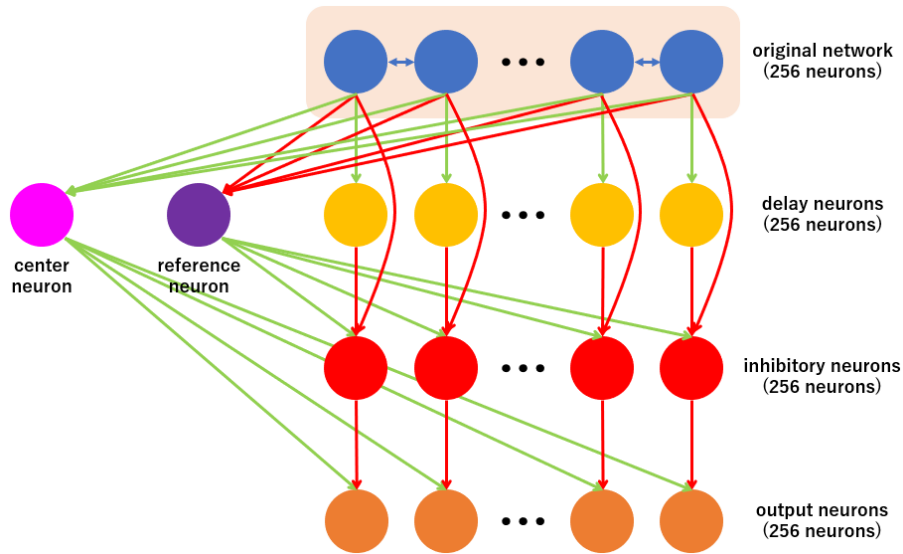


図 44 anti-synchronized な状態にある発火パターンの同期度を高めるためのネットワーク構造

4.3 同期度を高めるネットワーク

図 17 のような同期度 (=PSI) の低い発火パターンを 2 値のパターンとして解釈するためには、上述の dummy neuron に加え、何らかの追加のネットワーク構造を通すことによって同期度を高め、図 15 のような発火パターンに変換する必要がある。本節では前節の内容を踏まえ、そのような「発火パターンの同期度を高める」ためのネットワークについて述べる。

まず、ネットワーク構造としては図 44 のような構造を用いる。つまり、全ニューロンに共通して作用するニューロンとして前節で導入した「center neuron」、「reference neuron」の 2 つを用い、さらにもとの連想記憶ネットワーク中の 1 つ 1 つのニューロン (以下、説明の簡便のために original neuron と呼ぶ) に対して「delay neuron」「inhibitory neuron」「output neuron」の 3 つを用意する (よって、これらのニューロンは 256 ニューロンずつ用意することになる)。図中の矢印は信号の流れる向きを表しており、黄緑色の矢印が興奮性の結合、赤色の矢印が抑制性の結合を表している。最終的に 256 個の output neuron 群が、「もとの連想記憶ネットワークの同期度に関わらず」高い同期度で周期発火することになる。もとのネットワークの発火パターンの同期度がもともと高いときにも、このネットワーク構造は正しく動作する。

さて、前節で述べた center neuron と reference neuron の挙動を利用して「同期度を高める」ための基本的なアイデアは以下のようなになる。まず、(図 44 から分かるように) 各 original neuron は自分自身および center neuron、reference neuron から発火履歴に相当する情報を受け取って処理を進める。ここで、center neuron および reference neuron はネットワーク全体の発火の様子を個々のニューロンに伝えるような役割を果たす。「同期度を高める」ためには、個々のニューロンがこれらの情報をもとに「自分はどちらのニューロン群に属するのか」を判断し、その結果に応じて「center neuron の 1 回おきの発火時刻」に合わせて発火を起こすような仕組みを作ればよい。図 45 は、図 40 の状態に対応する「同期度を高めるネットワーク」の出力 (図 44 の output neuron 群のラスタプロット) である。この仕組みに従い、個々の output neuron は、「対応する original neuron が属さない方のニューロン群」に対応する center neuron の発火時刻から少し遅れた




図 45 図 40 の状態に対応する「同期度を高めるネットワーク」の出力 (図 44 の output neuron 群のラスタプロット)

時刻に発火している。

ここからは、図 44 のネットワーク構造によって上記のアイデアを実現する手法の詳細を述べる。図 46 は、図 40 の状態においてともに +1 を想起している 2 つの original neuron を例として取り出し (それぞれ上段および下段)、それぞれに対応する delay neuron、inhibitory neuron、output neuron および reference neuron、center neuron とともに示したラスタプロットである。もとのネットワークにおいて、上段のニューロンは「+1 を想起しているニューロン群」の中で比較的早い時刻に発火しているのに対し、下段のニューロンは同じ集団の中で比較的遅い時刻に発火している。reference neuron の連続する 2 つの発火時刻に挟まれた時間範囲を「区間」と呼ぶこととすると、オレンジ色で示される output neuron は (上でも述べたように) 対応する original neuron の発火時刻が含まれる区間の次の区間に発火しており、その発火時刻は上下段においてほぼ完全に揃っている (同期している)。

delay neuron はその名が示す通り、対応する original neuron の発火時刻から少し遅れて発火するという役割を持つ (図 46 において、そのようになっていることを確認できる)。このようなタイミングで発火を起こすには、図 44 にも示されているように、対応する original neuron だけから興奮性の入力 (=シナプス電流 I_s) を受け取ればよい。つまり、 i 番目の delay neuron への刺激入力 $I_{stim}^{i(delay)}$ は、

$$I_{stim}^{i(delay)} = D \cdot I_s^{i(original)} \quad (26)$$

のように計算される (D は正の係数)。

次に、各 inhibitory neuron は図 44 のように、reference neuron から興奮性の入力を受け取り、対応する original neuron および delay neuron から抑制性の入力を受け取る。つまり、 i 番目の inhibitory neuron への刺激入力 $I_{stim}^{i(inhibitory)}$ は、

$$I_{stim}^{i(inhibitory)} = E \cdot I_s^{reference} - F \cdot I_s^{i(original)} - G \cdot I_s^{i(delay)} \quad (27)$$

のように計算される (E, F, G は正の係数)。図 47 は、この式 27 によって表される inhibitory neuron の動作原理を各種ニューロンの波形によって表したものである。下段の 3 つの I_s の波形から式 27 に従って計算された $I_{stim}^{i(inhibitory)}$ の波形が上段の茶色の点線であり、これにより刺激された inhibitory neuron の膜電位の波形が




図 46 +1 を想起している 2 つのニューロンを例にとった、「同期度を高めるネットワーク」の動作原理を示すラスタープロット

赤色の実線である。それぞれの I_s の波形はそのニューロンの発火時刻に対応した周期的なピーク (山のような波形) を持っている。original neuron が一度発火してから次にまた発火するまでの間に reference neuron は 2 回発火するが、このうち「original neuron の発火の直後に起こる方の発火」に対応する波形のピーク (図中で suppressed と書かれている箇所) が起こそうとする inhibitory neuron の発火は、original neuron と delay neuron からの抑制性の項によって阻止される。一方で、「その次に起こる方の発火」に対応する波形のピーク (remain と書かれている箇所) は 3 つのニューロンの発火タイミングの関係から抑制性の項の影響をあまり受けないため、このピーク時刻に対応して inhibitory neuron は発火する。このように、対応する original neuron がどちらのニューロン群に属するかに応じて reference neuron の波形のピークが起こそうとする発火を 1 回おきに阻止する、というのが inhibitory neuron の動作原理であるが、図 46 の上段の例のように「original neuron の発火時刻」と「その直後の reference neuron の発火時刻」が大きく離れている場合には、original neuron からの抑制だけでは発火を阻止できない。delay neuron を導入するのは、このような場合にも発火を確実に阻止するためである。しかし一方でこの副作用として、図 46 の下段の例のように original neuron と直後の reference neuron の発火時刻が近い場合に、「阻止したくない方の発火」にまで少し抑制の影響が及んでしまい、結果として inhibitory neuron の発火時刻が対応するピーク時刻 (=reference neuron の発火時刻) からそこそこ遅れてしまう、ということが起こるため、inhibitory neuron 群の時点ではまだ完全な同期は起こらない。図 48 は、図 40 の状態に対応する inhibitory neuron 群のラスタープロットである。確かにまだ完全な同期は起こっていないが、各区間においてどの original neuron の発火時刻もその区間内での center neuron の発火時刻より少し先に来ている。このことは、これ以降に述べる output neuron の動作原理において重要な意味を持つ。

最後に、output neuron は図 44 のように center neuron から興奮性の入力を受け取り、対応する original neuron から抑制性の入力を受け取る。つまり、 i 番目の output neuron への刺激入力 $I_{stim}^{i(output)}$ は、

$$I_{stim}^{i(output)} = K \cdot I_s^{center} - L \cdot I_s^{i(inhibitory)} \quad (28)$$




図 47 図 44 における inhibitory neuron の動作原理




図 48 図 40 の状態に対応する (図 44 の)inhibitory neuron 群のラスタプロット

のように計算される (K, L は正の係数)。図 49 は、この式 28 によって表される output neuron の動作原理を各ニューロンの波形によって表したものである。下段の 2 つの I_s の波形から式 28 に従って計算された I_{stim}^{output} の波形が上段の茶色の点線であり、これにより刺激された output neuron の膜電位の波形がオレンジ色の実線である。inhibitory neuron が一度発火してから次にまた発火するまでの間に center neuron は 2 回発火するが、このうち「inhibitory neuron の発火の直後に起こる方の発火」に対応する I_s の波形のピーク (図中で suppressed と書かれている箇所) が起こそうとする output neuron の発火は inhibitory neuron からの抑制性の項によって阻止され、「その次に起こる方の発火」に対応する波形のピーク (remain と書かれている箇所) によって output neuron は発火する。これが上記のアイデアにおける「center neuron の 1 回おきの発火時刻に合わせて output neuron が発火を起こす」ことに対応する。上述のように inhibitory neuron の発火時刻は center neuron の「抑制をかけたい方の」発火時刻の少し前に必ず来ているので、先ほどの図 47 の場合のように遅れて発火するニューロンを導入する必要はない。よって、inhibitory neuron の動作原理にお




図 49 図 44 における output neuron の動作原理

けるような副作用は起こらず、式 28 で計算される $I_{stim}^{i(output)}$ の波形には center neuron の「抑制を受けない方」のピークの波形がほぼそのまま残る。従って、どの output neuron もこのような共通したピーク波形を受けて発火を起こすため、output neuron の発火時刻は図 45 のようにほぼ完全に同期する。

尚、上記では説明の簡便のために省略したが、上記の原理を効果的に動作させるために、図 44 のネットワーク構造における各結合の箇所ごとにシナプス電流 I_s の減衰の速さを決めるパラメータ β の調整も行っている。「同期度を高めるネットワーク」に関連する各種のパラメータの値は、本論文の末尾の付録に記載した。

本手法の妥当性を検証するため、図 12 の 4 つの銘記パターンそれぞれをベースとして 10%、20%、30% のエラーを入れた入力パターンを 100 通りずつ (合計で $100 \times 3 \times 4 = 1200$ 通り) 生成し、それらを入力としてもとの連想記憶ネットワークで想起を行った。十分な時間の経過後には 1200 通り全てにおいて銘記パターンのどれかが正しく想起され、この状態では図 44 の 256 個の output neuron 群の「PSI」および「4 つの銘記パターンそれぞれとの overlap のうちで最大のもの」は必ず 0.95 を越えている、つまり確かに同期度が高まっているということが確認された。

4.4 想起に失敗するケースの分類

この節では、SNN 上での連想記憶において想起に失敗したときに発生する現象に関して行った調査の結果を述べる。ここでまず、成功/失敗について議論するためには、どのような時に「想起に成功」と呼ぶのかを定義しなければならない。ある入力パターンを考えると、それと図 12 の 4 つの銘記パターンそれぞれとのハミング距離を測ることができる。「ハミング距離の尺度において、入力パターンに最も近い銘記パターン」を「真の銘記パターン」と呼ぶこととすれば、(第 2 章でも述べたように) 連想記憶ネットワークの挙動として直感的に最も望ましいのは、真の銘記パターンが想起される (それに対応する anti-synchronized な状態に到達する) ことだと考えられる。銘記パターンの 1 つにある割合のエラーを加えることで作成された入力パターンの場合、エラー率が 10% や 20% だとほぼ必ず真の銘記パターン (つまり入力パターン作成の際のベースとした銘記パターン) が想起されるが、エラー率が 30% 程度になると、「真の銘記パターンとは別の、銘記パターンのうちの 1 つ」が想起されることが時々ある。つまり、真の銘記パターンが銘記パターン 1 であるような入

力パターンを与えたにも関わらず、銘記パターン 4 が想起された (それに対応する anti-synchronized な状態に到達した)、というようなケースである。このような挙動は直感的にはあまり望ましくないが、本研究においてはこのようなケースも「想起に成功」したケースに含めることとする。つまり、以下のように定義する。

定義 1. 「想起に成功する」とは、「銘記パターンのいずれかが想起される」こと、つまり「発火パターンが銘記パターンのいずれかに対応する anti-synchronized な状態に到達する」ことである。

この定義のもとで「想起に成功しない」ケース、つまり「どの銘記パターンも想起されない」ケースにはどのようなものがあるかを調査するため、銘記パターンにエラーを入れるのではなくランダムに生成した 100000 通りの入力パターンを用いて想起を行ってみた。(尚、入力パターンの生成方法の性質上、この 100000 通りのパターンが全て互いに異なるとは限らず、重複は存在し得る。) このとき、想起を開始してから十分時間が経過した後 4 つの銘記パターンそれぞれとの overlap(式 18) の一定時間の平均値を計算したうえで、「そのうち最大のものが 0.8 を越えており、かつ、発火パターンが 4 つの銘記パターンのうちのどれか 1 つとして正しく解釈できた」ケースは想起に成功していると判断し、そうでないケースでの挙動を詳細に調査した。

その結果、100000 通りのうちの 2809 通りのケースが「想起に成功していない」と判断された。つまり、たとえランダムに生成した (銘記パターンのどれにもあまり近くないような) 入力パターンを与えても、多くの場合には銘記パターンのどれか 1 つが正しく想起されたということである。そして、「想起に成功しない」ケースにおいても発火パターンは必ず何らかの (どの銘記パターンにも対応づけられない) 定常状態、つまり各ニューロンが何らかの決まった周期で周期発火し続ける状態 (以下、「望ましくない定常状態」と呼ぶこととする) に到達し、さらに、そのような「望ましくない定常状態」は大きく以下のような 2 つのタイプに分類できることが分かった。

タイプ 1 各ニューロンが 2 種類の発火周期のうちのどちらかで発火する (2 種類の発火周期が共存する) 状態

タイプ 2 全ニューロンが同じ発火周期で発火する状態

また、詳細に発火パターンを観察することで、これらの 2 つのタイプはそれぞれ、さらにいくつかのサブタイプに分類できるようだということが分かった。以下、それぞれについて詳細を述べる。

4.4.1 タイプ 1 の「望ましくない定常状態」

図 50 は、タイプ 1 の「望ましくない定常状態」における各ニューロンの発火周期の例を示したものであり、横軸にニューロンのインデックスを、縦軸に発火周期をとっている。この例では、約 0.036 秒の長い発火周期をもつニューロン群 (192 ニューロン) と、約 0.025 秒の短い発火周期をもつニューロン群 (64 ニューロン) が共存していることが見て取れる。尚、同じタイプ 1 の状態でも、どのニューロンが長い (あるいは短い) 方の発火周期のニューロン群に含まれるかはその時与えた入力パターンによって異なり、2 つのニューロン群それぞれに含まれるニューロンの数もその時々で異なる。上記の 100000 通りの入力パターンのうち、2081 通りがこのタイプの定常状態に到達した。また、発火パターンがタイプ 1 の状態に到達したケースにおいて、長い発火周期のニューロン群に +1 を、短い発火周期のニューロン群に -1 をそれぞれ割り当ててパターンとして解釈してみると (対応関係は逆でもよい)、このパターンは必ず図 12 の 4 つの銘記パターン全てと直交していた。

図 51 は、図 50 のケースに対応するラスタプロットである。長い周期で発火するニューロン群をオレンジ色の点で、短い周期で発火するニューロン群を青色の点で示している。このケースでは、短い発火周期のニューロン群はさらに 2 つの同期した集団に分かれて anti-synchronized な状態で発火しているが、長い発火周期のニューロン群では各ニューロンはばらばらな位相で発火していることが見て取れる。このような状態




図 50 タイプ 1 の「望ましくない定常状態」における各ニューロンの発火周期の例




図 51 タイプ 1-1 の「望ましくない定常状態」におけるラスタプロットの例

を、タイプ 1-1 と呼ぶこととする。図 52 は、図 50 および図 51 のケースに対応する PSI(全体、長い周期のニューロン群のみ、短い周期のニューロン群のみ、のそれぞれで計算した 3 種類) と overlap の時間変化を示している。上記の発火パターンに対応し、短い周期のニューロン群のみの PSI は 1 に近く、長い周期のニューロン群のみの PSI はほぼ 0 になっている。また、2 種類の発火周期が共存しているにも関わらず、ネットワーク全体の PSI も 0.7 秒あたりから一定値を保っている。これは、PSI の式 17 における全ニューロンに関する総和を「長い周期のニューロン群のみに関する総和」と「短い周期のニューロン群のみに関する総和」とに分解でき、このうち前者が定常的にほぼ 0 になるためだと考えられる。また、overlap も 0.7 秒あたりから一定値を保っており、4 つの銘記パターンそれぞれとの overlap は全て同じ値となっている。

図 53 と図 54 はタイプ 1 の状態に到達した別のケースにおけるラスタプロット、および PSI と overlap の時間変化を示している。このケースでは、短い発火周期のニューロン群は全ニューロンが同期して発火しており、長い発火周期のニューロン群では 2 つの集団が anti-synchronized な状態で発火している。このように、長い周期のニューロン群と短い周期のニューロン群の両方がそれぞれ同期した位相で発火しているような




図 52 タイプ 1-1 の「望ましくない定常状態」における PSI と overlap の時間変化の例




図 53 タイプ 1-2 の「望ましくない定常状態」におけるラスタープロットの例

状態をタイプ 1-2 と呼ぶこととする。(尚、短い周期のニューロン群が 2 つの anti-synchronized な集団に分かれている場合もあり、そのようなケースもこのタイプに含める。) このタイプでは、長い周期のニューロン群のみ、短い周期のニューロン群のみの PSI がともに 1 に近い値をとっている。その結果、上記のように PSI の式 17 を 2 つの項に分解した際に、それぞれの項が異なる周期で振動しているため、ネットワーク全体の PSI は一定値にはならず、一定の周期で振動し続けている。また、4 つの銘記パターンそれぞれとの overlap は図 52 のケースと同様に全て同じ値に収束している。

この調査で確認された 2081 通りのタイプ 1 の状態は全て、タイプ 1-1 またはタイプ 1-2 のどちらかに分類された。




図 54 タイプ 1-2 の「望ましくない定常状態」における PSI と overlap の時間変化の例

4.4.2 タイプ 2 の「望ましくない定常状態」

図 55 は、タイプ 2 の「望ましくない定常状態」における各ニューロンの発火周期の例を示したものである。この例では、全ニューロンが同一の約 0.037 秒の発火周期をもっていることが見て取れる。上記の 100000 通りの入力パターンのうち、728 通りがこのタイプの定常状態に到達した。

図 56 は、図 55 のケースに対応するラスタプロットである。anti-synchronized な状態で発火している 2 つの (同数のニューロンを含む) ニューロン群が見て取れるが、2 つのニューロン群のどちらかに +1 を、もう一方に -1 を割り当てて 2 値のパターンとして解釈してみても、図 12 の 4 つの銘記パターンのどれとも一致しないため、銘記パターンのどれかが想起されているわけではない。ただ、そのようにして解釈された 2 値のパターンは、4 つの銘記パターンのうちのどれか 1 つだけ (このケースでは銘記パターン 3) と直交している。このような状態をタイプ 2-1 と呼ぶこととする。図 57 は、図 55 および図 56 のケースに対応する PSI と overlap の時間変化を示している。タイプ 2 の状態では全ニューロンの発火周期が等しいので、PSI と overlap は一定の値に収束している。また、4 つの銘記パターンそれぞれとの overlap のうち、銘記パターン 3 との overlap だけが 0 に収束している。これは、上で述べたように図 56 の発火パターンから解釈された 2 値のパターンが銘記パターン 3 とだけ直交していることに対応していると考えられる。

図 58 と図 59 はタイプ 2 の状態に到達した別のケースにおけるラスタプロット、および PSI と overlap の時間変化を示している。このケースでも anti-synchronized な状態で発火している 2 つのニューロン群が見て取れるが、2 つのニューロン群に含まれるニューロンの数は等しくない (この例では片方の群に 234 ニューロンが、もう一方の群に 22 ニューロンが含まれている)。2 つのニューロン群に +1 および -1 を割り当てて 2 値のパターンとして解釈してみると、得られたパターンは 4 つの銘記パターン全てと直交している。このような状態をタイプ 2-2 と呼ぶこととする。このケースでも PSI および overlap は一定値に収束しているが、4 つの銘記パターンそれぞれとの overlap は全て 0 になっている。これも、発火パターンから解釈された 2 値のパターンが 4 つの銘記パターン全てと直交していることに対応していると考えられる。

図 60 はタイプ 2 の状態に到達した、さらに別のケースにおけるラスタプロットである。このケースでは、全てのニューロンが完全に位相を揃えて同期発火している。このような状態をタイプ 2-3 と呼ぶこととする。

図 61 もまた、タイプ 2 の状態に到達した、さらに別のケースにおけるラスタプロットである。このケースでは、同数のニューロンを含むそれぞれ同期した 4 つの集団が一定の順番で繰り返し発火している。このよ




図 55 タイプ 2 の「望ましくない定常状態」における各ニューロンの発火周期の例




図 56 タイプ 2-1 の「望ましくない定常状態」におけるラスタプロットの例




図 57 タイプ 2-1 の「望ましくない定常状態」における PSI と overlap の時間変化の例




図 58 タイプ 2-2 の「望ましくない定常状態」におけるラスタープロットの例




図 59 タイプ 2-2 の「望ましくない定常状態」における PSI と overlap の時間変化の例

うな状態をタイプ 2-4 と呼ぶこととする。

この調査で確認された 728 通りのタイプ 2 の状態は全て、タイプ 2-1 からタイプ 2-4 までの 4 つのどれかに分類された。




図 60 タイプ 2-3 の「望ましくない定常状態」におけるラスタープロットの例




図 61 タイプ 2-4 の「望ましくない定常状態」におけるラスタープロットの例

4.5 「望ましくない定常状態」を検出する手法

この節では 4.4 節での調査結果に基づき、想起に失敗した状態、つまり「望ましくない定常状態」の発生を検出する手法を提案する。4.4 節で述べたように、「望ましくない定常状態」はタイプ 1 とタイプ 2 の 2 種類に分類され、タイプ 1 とタイプ 2 の状態はそれぞれ、さらにいくつかのサブタイプに分類される。タイプごとに状態の性質は大きく異なるので、1 つの手法で全てのタイプの「望ましくない定常状態」を検出することはあまり現実的ではない。ここでは、これらのうちのタイプ 1、タイプ 2-2 およびタイプ 2-3 の状態を検出する手法として、2 つの異なるアプローチによる手法を提案する。




図 62 想起に成功した状態および「望ましくない定常状態」における発火周期の分布 (ヴァイオリンプロット)

4.5.1 発火周期の違いに着目した手法

1 つめの手法では、「想起に成功した定常状態」と「望ましくない定常状態」における各ニューロンの発火周期の違いに着目してその検出を行う。図 62 は、こうした様々な定常状態におけるニューロンの発火周期の分布を示した図である。この図はヴァイオリンプロットと呼ばれ、横軸に示された定常状態のタイプごとに、多数の入力を用いたシミュレーションから得られた発火周期の値の頻度分布を縦方向に示している (図中の n は分布をとったサンプル数)。尚、タイプ 1 の状態に関しては、長い方の周期をもつニューロン群と短い方の周期をもつニューロン群で分けて分布を示している。この図より、それぞれの状態において、とり得る発火周期の値はある程度決まっているということが分かる。つまり、例えばタイプ 1 の状態における短い方の周期や、タイプ 2-2 やタイプ 2-3 における周期の値は、0.025 秒付近のある 1 つの値しかとり得ないということである。そしてその値は、想起に成功した状態での発火周期がとり得る 0.04 秒付近の値とは比較的大きく離れている。よって、この違いに着目してタイプ 1、タイプ 2-2 およびタイプ 2-3 の「望ましくない定常状態」を検出することが可能である。

この手法では、発火周期 (つまり発火周波数) の違いを検出するために、クラス 2 ニューロンのもつ周波数選択性という特性を利用する。これは、クラス 1 ニューロンにはない特性である。よって、まずはこれについて説明する。図 4 や図 8 で述べたように、クラス 1 とクラス 2 のどちらにおいても、刺激電流 I_{stim} の値が小さいときには位相平面上に静止状態に対応する安定な固定点が存在し、パルス刺激などによって固定点を離れた位相平面上の状態点はベクトル場に従ってやがて再び固定点に戻ってくるが、この時クラス 2 においてのみ subthreshold oscillation と呼ばれる減衰振動が観測される。この subthreshold oscillation の存在により、クラス 2 のニューロンは図 63 のような周波数選択性を示す [2]。図 63 は、様々な間隔 (つまり周波数) で到着するパルス刺激に対するクラス 2 のニューロンの応答を位相平面上の軌道と膜電位の波形を対応させて示したものである。パルス刺激の間隔が長すぎても短すぎてもニューロンは発火せず、中ぐらいの間隔で到着するパルス刺激に対してのみ発火が起こっている。唯一発火を引き起こしている中段の図では、あるパルスによって引き起こされた subthreshold oscillation が位相平面上でちょうど一周したぐらいのタイミングでその次のパルスが到着し、状態点を v ナルクラインから大きく離れた位置に押しやることで効果的に膜電位を上昇させていることがわかる。一方で、パルス刺激の間隔が subthreshold oscillation の周期と比べて長すぎたり短すぎたりすると、 v の値が減少しつつあるタイミングで次のパルスが到着するため、効果的に膜電位を引き上げられ

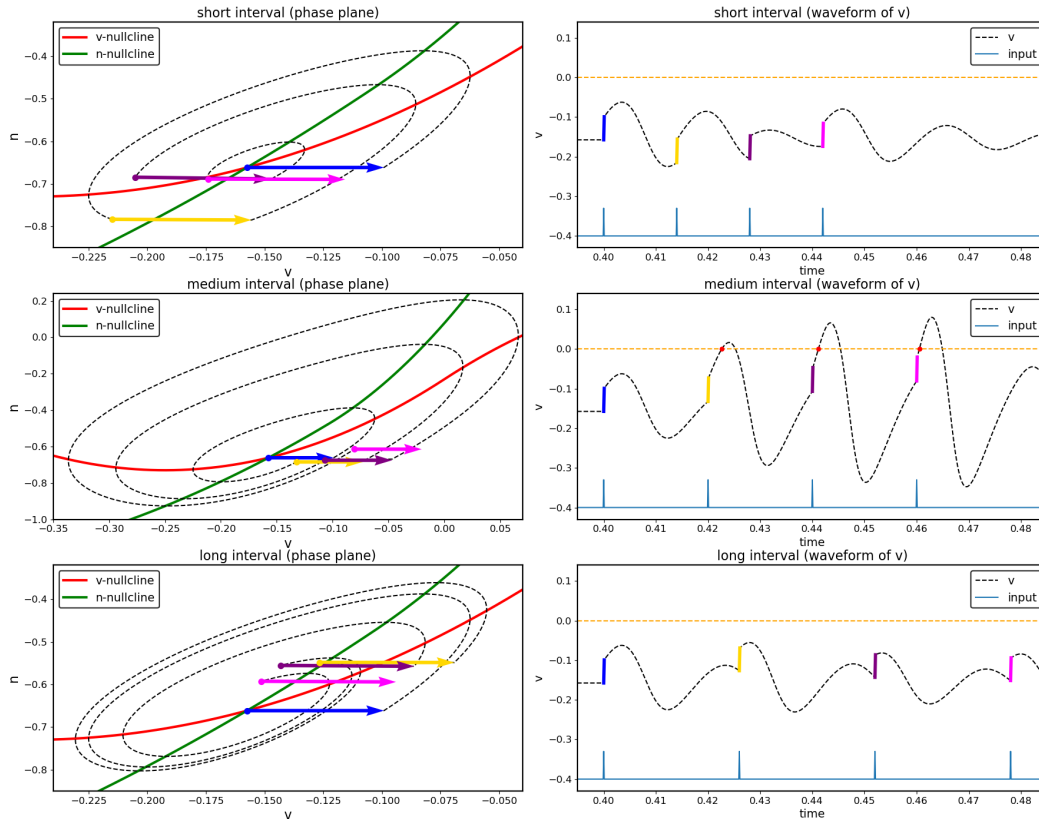


図 63 クラス 2 のニューロンモデルの周波数選択性

ていない。よって、subthreshold oscillation の周期とおおよそ同じくらいの間隔で到着するパルス刺激のみが発火を引き起こしうる、つまり「選択される」ということになる。

さて、このようなクラス 2 の周波数選択性を利用した具体的な検出方法としては、図 64 の左側のように、もとの連想記憶ネットワーク中の 1 つ 1 つのニューロンに対して対応する 1 つのクラス 2 ニューロンを用意する。そして、各クラス 2 ニューロンはもとの連想記憶ネットワーク中の対応するニューロンとの間のみ結合をもち、入力 (シナプス電流 I_s) を受け取る。さらに、全てのクラス 2 ニューロンに対し、(刺激電流 $I_{stim} = 0$ のもとで) タイプ 1 の状態における短い方の発火周期 (図 62 より 0.025 秒程度) を「選択」するように調整したパラメータを一律に付与する。検出方法は、以下のようになる。

1. 連想記憶ネットワークがタイプ 1 の「望ましくない定常状態」にあるとき、「短い方の周期で発火しているニューロンに対応するクラス 2 ニューロン」だけが周期発火する。
2. 連想記憶ネットワークがタイプ 2-2 またはタイプ 2-3 の「望ましくない定常状態」にあるとき、全てのクラス 2 ニューロンが周期発火する。
3. 連想記憶ネットワークが「想起に成功した状態」にあるとき、どのクラス 2 ニューロンも発火しない。

以下では、クラス 2 ニューロンのパラメータを調節する手順について述べる。上述のように、クラス 2 ニューロンが選択する周期 (つまり周波数) は、安定固定点 (v ナルクラインと n ナルクラインの交点) まわりでの subthreshold oscillation (減衰振動) の周期 (周波数) とおおよそ等しくなる。[21] におけるオリジナルの

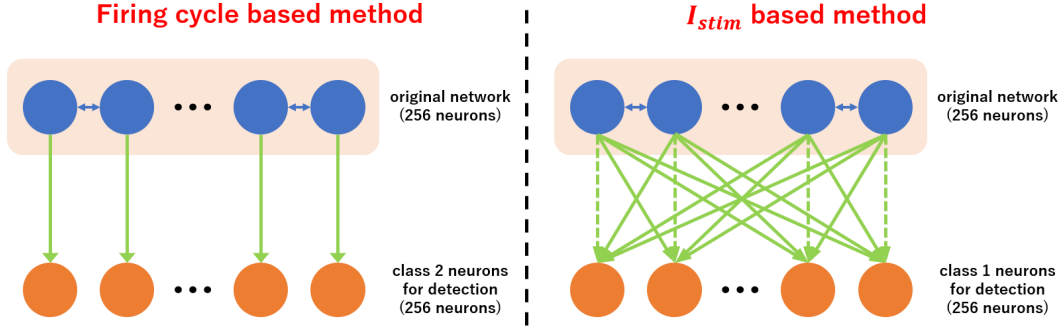


図 64 「望ましくない定常状態」を検出する 2 種類の手法におけるネットワーク構造

パラメータ設定において、 $I_{stim} = 0$ のときのナルクラインの交点の座標を (v_0, n_0) とすると、この点は v ナルクラインを定める関数 $g(v)$ の区分を分けている $v = r$ よりも左側にあり、この交点におけるヤコビ行列は、

$$A = \begin{pmatrix} \frac{\partial F}{\partial v}(v, n) & \frac{\partial F}{\partial n}(v, n) \\ \frac{\partial G}{\partial v}(v, n) & \frac{\partial G}{\partial n}(v, n) \end{pmatrix} \bigg|_{(v,n)=(v_0,n_0)} = \frac{1}{\tau} \begin{pmatrix} 2\phi a_n(v_0 + b_n) & -\phi \\ 2k_n(v_0 - p_n) & -1 \end{pmatrix} \quad (29)$$

と表される。このヤコビ行列の固有値を λ とすると、固有方程式は

$$\lambda^2 - \frac{1}{\tau} \{2\phi a_n(v_0 + b_n) - 1\} \lambda + \frac{2\phi}{\tau^2} \{k_n(v_0 - p_n) - a_n(v_0 + b_n)\} = 0 \quad (30)$$

となり、これより固有値は

$$\lambda = \frac{2\phi a_n(v_0 + b_n) - 1}{2\tau} \pm \frac{\sqrt{8\phi \{k_n(v_0 - p_n) - a_n(v_0 + b_n)\} - \{2\phi a_n(v_0 + b_n) - 1\}^2}}{2\tau} i \quad (31)$$

と求められる。この固有値の虚部が subthreshold oscillation の角周波数 ω となることから、その周期 T はおよそ

$$T \approx \frac{2\pi}{\omega} = \frac{4\pi\tau}{\sqrt{8\phi \{k_n(v_0 - p_n) - a_n(v_0 + b_n)\} - \{2\phi a_n(v_0 + b_n) - 1\}^2}} \quad (32)$$

と求められる。オリジナルのパラメータ設定においてこの周期 T を計算してみると、 $T \approx 0.02$ 秒程度の値となる。それに対して、今回選択したい「タイプ 1 の状態における短い方の発火周期」は 0.025 秒程度であるから、パラメータを調整することで T の値を大きくすることを考える。どのパラメータの値を変えてもよいのだが、今回は式 32 においてシンプルで入っている（つまり、値を変化させることによる T への影響が分かりやすい） k_n の値を変更する。オリジナルのパラメータ設定では $k_n = 4.0$ であるので、（他のパラメータの値は v_0 も含めて全て固定したうえで）これを少し小さくして $k_n = 3.125$ とすると、 $T \approx 0.0264$ 程度の値になる。よって、まず $k_n = 3.125$ と変更したうえで、この変更によって不都合が生じないように他のいくつかのパラメータの値もあわせて変更する。具体的な手順としては、

1. $k_n = 3.125$ と変更する。
2. 1. の変更によってナルクラインの交点の位置 (v_0, n_0) が変わらないように、 q_n の値を変更する。
3. 1. および 2. の変更を加えたうえで、 $(v = r$ の左側と右側でそれぞれ別の式で表される) n ナルクラインの両側が「連続かつ滑らかに」接続するように、 k_p と q_p の値を変更する。




図 65 オリジナルおよびパラメータ調整後のナルクライン

とする。手順 3. では、具体的には「 $v = r$ における n の値が左側と右側で等しい」かつ「 $v = r$ における傾きが左側と右側で等しい」という条件を課す。つまり、

$$\begin{cases} k_n(r - p_n)^2 + q_n = k_p(r - p_p)^2 + q_p \\ 2k_n(r - p_n) = 2k_p(r - p_p) \end{cases} \quad (33)$$

とする。結果的に、オリジナルのクラス 2 のパラメータ群から k_n, q_n, k_p, q_p の 4 つのパラメータの値を変更することとなり、変更後の値はそれぞれ

$$k_n = 3.125, q_n = -1.174186642, k_p = 12.5, q_p = -0.681836382 \quad (34)$$

となる。図 65 はオリジナルおよびパラメータ調整後のナルクラインを示している。変更した 4 つのパラメータは n ナルクラインにしか関係しないので、 n ナルクラインの形状のみが変化している。 v ナルクラインとの交点の位置 (v_0, n_0) は、パラメータ調整の前後で変化していない。図 66 はオリジナルおよび調整後のパラメータを用いたクラス 2 の DSSN モデルに単発のパルス状の刺激を与えたときの subthreshold oscillation の波形を示している。左の図がオリジナルの、右の図が調整後のパラメータでの結果を示している。振動の周期は確かに左の図では 0.02 秒程度に、右の図では 0.026 秒程度になっていることが見て取れる。

上記のように特性を調整されたクラス 2 ニューロンは、もとの連想記憶ネットワーク中の対応する 1 つのニューロンからシナプス電流 I_s を受け取る。このシナプス電流のダイナミクスは式 13 で表されるが、上述のクラス 2 ニューロンの周波数選択性は基本的には一定の間隔で到着するインパルス状の入力を想定したものであるから、シナプス電流の波形をインパルス状の波形に近づけるため、式 13 におけるパラメータ β の値を [21] におけるオリジナルの値より少し大きくして $\beta = 500$ とすることで減衰の時定数を短くする。また、連想記憶ネットワーク中のニューロンから対応するクラス 2 ニューロンへの結合荷重の値は、全て一律に $W = 0.3$ とする。

図 67 は、もとの連想記憶ネットワークがタイプ 1 の状態にあるときの、もとのネットワーク中のニューロンから発せられるシナプス電流およびそれを入力として受け取るクラス 2 ニューロンの膜電位の波形を示している。左図がもとのネットワークにおいて長い発火周期を持つニューロン、右図が短い発火周期を持つニューロンに対応する。左図ではシナプス電流の波形のあるピークによって引き起こされた subthreshold oscillation

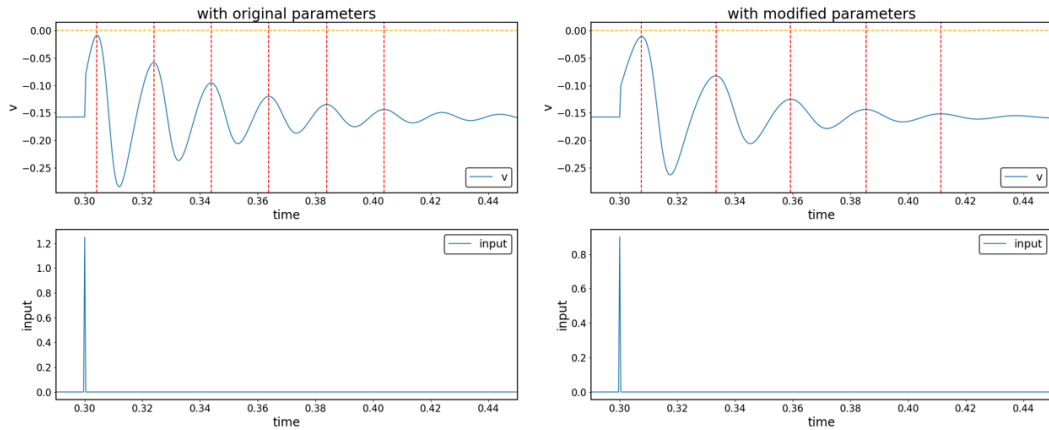


図 66 もとのパラメータおよび変更後のパラメータ設定における subthreshold oscillation




図 67 クラス 2 ニューロンを用いた、長い発火周期と短い発火周期の識別

において膜電位が減少しつつあるタイミングで次のピークが到着しているため膜電位を大きく引き上げられず、クラス 2 ニューロンは発火していない。一方で右図では、subthreshold oscillation の周期とシナプス電流の波形のピークが到着する間隔がほぼ一致しているため、クラス 2 ニューロンは共振を起こして発火している。このようにして、短い周期で発火するニューロンから入力を受け取るクラス 2 ニューロンだけが選択的に発火する。また、連想記憶ネットワークがタイプ 2-2 または 2-3 の状態にあるときには、図 62 より全てのニューロンが 0.025 秒程度の発火周期をもつため、それに対応して全てのクラス 2 ニューロンが発火する。一方で、想起に成功した状態においては、全てのニューロンがタイプ 1 の状態における長い方の周期と同程度の発火周期をもつため、それに対応してどのクラス 2 ニューロンも発火しない。

図 68 および図 69 は、それぞれタイプ 1-1 およびタイプ 2-2 の状態における、もとの連想記憶ネットワーク (上段) とそこから入力を受け取る同数の検出用クラス 2 ニューロン群 (下段) のラスタプロットの例を示している。図 68 においては短い周期で発火するニューロンから入力を受け取るクラス 2 ニューロンだけが、図 69 においては全てのクラス 2 ニューロンが、連想記憶ネットワーク中の対応するニューロンの発火時刻から少し遅れて周期発火していることが確認できる。4.4 節の調査で確認された全てのタイプ 1、タイプ 2-2 およびタイプ 2-3 の状態を、この手法によって検出できることを確認した。




図 68 クラス 2 ニューロンを用いた、タイプ 1-1 の状態の検出の例




図 69 クラス 2 ニューロンを用いた、タイプ 2-2 の状態の検出の例




図 70 タイプ 1 の状態における、長い周期のニューロンと短い周期のニューロンの v および I_{stim} の波形

4.5.2 刺激入力 I_{stim} の波形に着目した手法

2 つめの手法では、「望ましくない定常状態」において発生する各ニューロンへの刺激入力 I_{stim} の特殊な波形に着目してその検出を行う。上述のように、連想記憶ネットワークにおいて各ニューロンは刺激入力 I_{stim} を受け取り、その膜電位 v を変化させる。 I_{stim} は式 14 のように、「他のニューロンからのシナプス電流 I_s の荷重和」と「外部から実験者が与える電流 I_{ext} 」の 2 つの成分からなり、「想起に成功した定常状態」においては図 16 や図 18 のような波形となっている。一方で、図 70 はタイプ 1 の「望ましくない定常状態」における、長い周期を持つニューロン (上段) と短い周期を持つニューロン (下段) の v および I_{stim} の波形を示している。この図を見ると、長い周期のニューロンへの I_{stim} の波形は図 18 と似たような波形で v の周期 (発火周期) と等しい周期で振動しているのに対し、短い周期のニューロンへの I_{stim} の波形はほぼ定常電流のようになっていることが分かる。つまり、上記の 2 つの成分のうち、(シミュレーション開始直後以外は定値刺激となっている) 外部入力の成分しかほぼなく、他のニューロンからのシナプス電流 I_s の荷重和の成分は定常的にほぼ 0 になっている、ということである。 I_{stim} がこのような特殊な波形になる理由は今のところ解明できていないが、上記の 100000 通りのランダム入力を用いたシミュレーションで観測された全てのタイプ 1 の状態において、短い周期を持つ全てのニューロンの I_{stim} がこのような波形になっていた。さらに、同じく観測された全てのタイプ 2-2 およびタイプ 2-3 の状態において、ネットワーク中の全ニューロンの I_{stim} がこのような波形になっていた。「発火周期の違いに着目した手法」の節でも述べたが、タイプ 2-2 およびタイプ 2-3 の状態においては、全ニューロンが「タイプ 1 の状態における短い方の発火周期」と同じ値の発火周期を持っている (図 62)。よって、詳細は今のところ分からないが、この 0.025 秒程度の発火周期とこの I_{stim} の特殊な波形との間に何らかの対応関係があるのではないかと考えられる。

さて、この現象がタイプ 1、タイプ 2-2 およびタイプ 2-3 の状態においては必ず成り立っていると仮定すると、これを利用してこれらの「望ましくない定常状態」を検出する手法を考えることができる。具体的には、図 64 の右側のように、もとの連想記憶ネットワーク中の 1 つ 1 つのニューロンに対して、対応する 1 つの検出用クラス 1 ニューロンを用意する。そして、各検出用ニューロンをもとの連想記憶ネットワーク中の対応するニューロンの I_{stim} の「他のニューロンからのシナプス電流の荷重和」の成分だけで刺激する。つまり、各

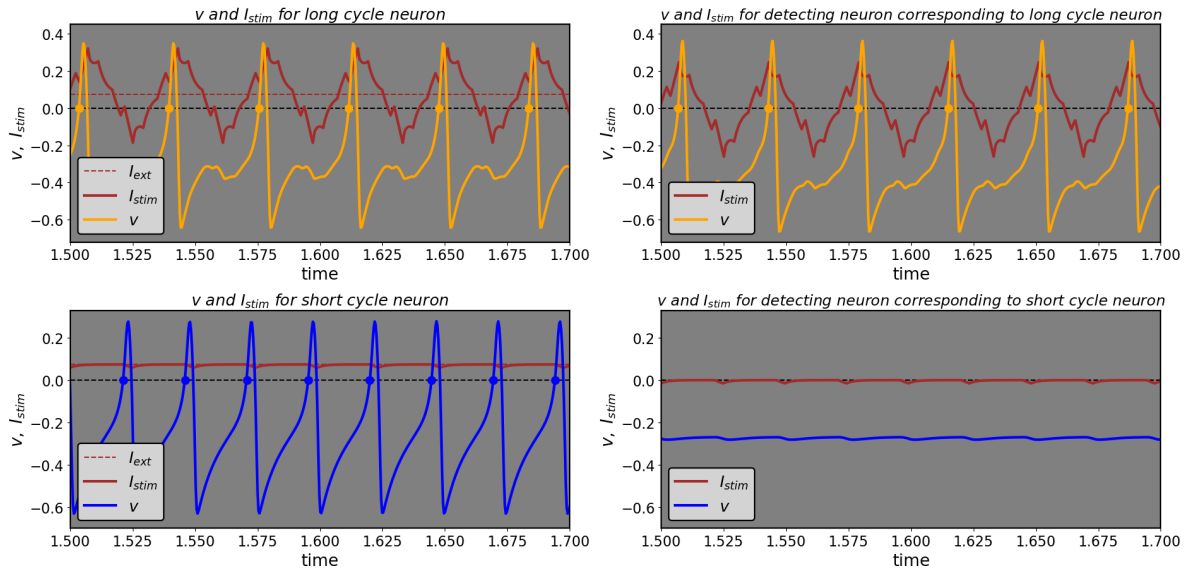


図 71 I_{stim} の波形に着目した検出方法の原理 (もとの連想記憶ネットワーク中のニューロン (左) および それに対応する検出用ニューロン (右) の、 v および I_{stim} の波形)

検出用ニューロンはもとの連想記憶ネットワーク中の全てのニューロンとの間に結合をもち、対応するニューロンが他のニューロンから受けている結合と全く同じ荷重値を検出用ニューロンへの各結合に対して設定する。そして、各検出用ニューロンへの外部からの入力 I_{ext} は常に 0 とする。この手法が働く原理を示したのが図 71 である。左側にはタイプ 1 の状態における長い周期のニューロンと短い周期のニューロンの、右側にはそれぞれに対応する検出用ニューロンの v および I_{stim} の波形を示している。図の右側の検出用ニューロンへの I_{stim} の波形を左側の波形と見比べると、外部からの入力 I_{ext} の成分がない分だけ垂直下方向にシフトした波形になっていることが分かる。長い周期のニューロンでは「シナプス電流の荷重和」の成分は土両方向にわたって (発火周期と等しい周期で) 振動しているため、対応する検出用ニューロンはそれに合わせて周期発火しているが、短い周期のニューロンでは上記のようにこの成分が定常的にほぼ 0 になっているため、対応する検出用ニューロンは発火していない。つまり、長い周期のニューロンに対応する検出用ニューロンのみが発火することになる。加えて、上述の様々なタイプの状態における I_{stim} の波形の観察を踏まえると、この手法による検出方法は以下になる。

1. 連想記憶ネットワークがタイプ 1 の「望ましくない定常状態」にあるとき、「長い方の周期で発火しているニューロンに対応する検出用ニューロン」だけが周期発火する。
2. 連想記憶ネットワークがタイプ 2-2 またはタイプ 2-3 の「望ましくない定常状態」にあるとき、どの検出用ニューロンも発火しない。
3. 連想記憶ネットワークが「想起に成功した状態」にあるとき、全ての検出用ニューロンが周期発火する。

図 72 は、タイプ 1-2 の状態における、もとの連想記憶ネットワーク (上段) とそこから入力を受け取る同数の検出用クラス 1 ニューロン群 (下段) のラスタプロットの例を示している。上記のように、長い方の周期で発火するニューロンから入力を受け取る検出用ニューロンだけが、連想記憶ネットワーク中の対応するニューロンの発火時刻から少し遅れて周期発火していることが確認できる。4.4 節の調査で確認された全ての




図 72 I_{stim} の波形に着目した、タイプ 1-2 の状態の検出の例

タイプ 1、タイプ 2-2 およびタイプ 2-3 の状態を、この手法によって検出できることを確認した。

5 結論

本研究では、SNN 上での連想記憶を実行する電子回路モジュールを作成するという将来的な目的に向けて、そのデジタルコンピュータとの間のインターフェース部分に関するいくつかの手法を提案した。

まず、想起が成功した場合の anti-synchronized な発火パターンを 2 値の出力パターンに変換するための手法として、dummy neuron および同期度を高めるネットワークを提案した。同期度を高めるネットワークによって交互に発火する 2 つのニューロン群それぞれの同期度を高めたとうえで、+1 の要素に対応するニューロン群と同期する dummy neuron の発火時刻をクロックとして、2 値の出力パターンを正しく取り出すことができると考えられる。ただ、今回提案した同期度を高めるネットワークは、もとの連想記憶ネットワークのニューロン数に対して 3 倍程度の追加のニューロン数を必要とする。今後の課題として、さらなる低消費電力化のために、より少ないニューロン数で同期度を高められる仕組みを考案する必要がある。

また、想起が失敗した時に発生する現象の調査を行い、銘記パターンセットのどれにも対応づけられないような「望ましくない定常状態」が存在すること、およびそれが大きく 2 つのタイプに分類できることを発見した。ただ、この結果はあくまでも限られた回数のシミュレーション実験に基づいたものであるもので、これら 2 つのタイプのどちらにも該当しないような「望ましくない定常状態」が存在しないとは必ずしも言い切れない。今後の課題として、今回発見されたタイプの「望ましくない定常状態」がどのようにして発生するのかということも含めた理論的な解析が必要である。

また、今回発見された「望ましくない定常状態」のうちのいくつかのタイプを検出する手法として、2 つの異なるアプローチに基づいた手法を提案した。刺激電流 I_{stim} の特殊な波形に着目した手法は、クラス 2 ニュー

ロンを用いる手法と比べて綿密なパラメータ調整が不要だという利点があるが、「望ましくない定常状態」においてこのような特殊な刺激電流の波形が発生する理由は明らかにできておらず、この点に関する理論的な解析が必要である。また、クラス 2 ニューロンを用いた手法において今回は手動でパラメータの調整を行ったが、より汎用性を高めるためには、生体に倣って各クラス 2 ニューロンが正しく検出を行えるパラメータを自律的に獲得していくような仕組みを考える必要がある。最後に、今回提案した検出方法では、4.4 節で述べた「望ましくない定常状態」のうちのタイプ 1、タイプ 2-2 およびタイプ 2-3(図 62 を参照) の状態を検出できるが、タイプ 2-1 およびタイプ 2-4 の状態は検出できない。よって、これらの状態を検出するための手法を今後考える必要がある。

謝辞

本論文の作成にあたり、適切なご助言と丁寧なご指導を頂きました指導教官の河野崇教授に深く感謝申し上げます。また、研究に関して貴重なご助言を頂きました合原一幸教授および藤田昌宏教授に深く感謝いたします。最後に、研究に関する相談に乗って頂き、様々な角度から有益なご助言を頂きました河野研究室の皆様に深く感謝いたします。

参考文献

- [1] Gerstner, Wulfram, and Werner M. Kistler. Spiking neuron models: Single neurons, populations, plasticity. Cambridge university press, 2002.
- [2] Izhikevich, Eugene M. Dynamical systems in neuroscience. MIT press, 2007.
- [3] 合原一幸, and 神崎亮平. "理工学系からの脳科学入門." (2008).
- [4] Hodgkin, Alan L. "The local electric changes associated with repetitive action in a non - medullated axon." *The Journal of physiology* 107.2 (1948): 165-181.
- [5] Rinzel, John, and G. Bard Ermentrout. "Analysis of neural excitability and oscillations." *Methods in neuronal modeling* 2 (1998): 251-292.
- [6] Hebb, Donald O. "The organization of behavior." (1949).
- [7] Markram, Henry, et al. "Regulation of synaptic efficacy by coincidence of postsynaptic APs and EPSPs." *Science* 275.5297 (1997): 213-215.
- [8] Kohno, Takashi, Jing Li, and Kazuyuki Aihara. "Silicon neuronal networks towards brain-morphic computers." *Nonlinear Theory and Its Applications, IEICE* 5.3 (2014): 379-390.
- [9] Ambroise, Matthieu, et al. "Real-time biomimetic central pattern generators in an FPGA for hybrid experiments." *Frontiers in neuroscience* 7 (2013): 215.
- [10] Saighi, Sylvain, et al. "A library of analog operators based on the Hodgkin-Huxley formalism for the design of tunable, real-time, silicon neurons." *IEEE transactions on biomedical circuits and systems* 5.1 (2011): 3-19.
- [11] Hodgkin, Alan L., and Andrew F. Huxley. "A quantitative description of membrane current and its application to conduction and excitation in nerve." *The Journal of physiology* 117.4 (1952): 500-544.
- [12] Brunel, Nicolas, and Mark CW Van Rossum. "Quantitative investigations of electrical nerve excitation treated as polarization." *Biological Cybernetics* 97.5-6 (2007): 341-349.
- [13] Merolla, Paul A., et al. "A million spiking-neuron integrated circuit with a scalable communication network and interface." *Science* 345.6197 (2014): 668-673.
- [14] Izhikevich, Eugene M. "Simple model of spiking neurons." *IEEE Transactions on neural networks* 14.6 (2003): 1569-1572.
- [15] FitzHugh, Richard. "Impulses and physiological states in theoretical models of nerve membrane." *Biophysical journal* 1.6 (1961): 445-466.
- [16] Kohno, Takashi, and Kazuyuki Aihara. "A mathematical-structure-based aVLSI silicon neuron model." *Proceedings of the 2010 International Symposium on Nonlinear Theory and its Applications*. 2010.
- [17] Kohno, Takashi, and Kazuyuki Aihara. "Digital spiking silicon neuron: concept and behaviors in GJ-coupled network." *Proceedings of International Symposium on Artificial Life and Robotics*. Vol. 2007. 2007.
- [18] Morris, Catherine, and Harold Lecar. "Voltage oscillations in the barnacle giant muscle fiber." *Biophysical journal* 35.1 (1981): 193-213.
- [19] Strogatz, Steven H. *Nonlinear dynamics and chaos: with applications to physics, biology, chemistry,*

- and engineering. CRC Press, 2018.
- [20] Destexhe, Alain, Zachary F. Mainen, and Terrence J. Sejnowski. "Kinetic models of synaptic transmission." *Methods in neuronal modeling* 2 (1998): 1-25.
 - [21] Li, Jing, Yuichi Katori, and Takashi Kohno. "An FPGA-based silicon neuronal network with selectable excitability silicon neurons." *Frontiers in neuroscience* 6 (2012): 183.
 - [22] Hopfield, John J. "Neural networks and physical systems with emergent collective computational abilities." *Proceedings of the national academy of sciences* 79.8 (1982): 2554-2558.
 - [23] Li, Jing, Yuichi Katori, and Takashi Kohno. "Hebbian learning in fpga silicon neuronal network." *Proceedings of The 1st IEEE/IIAE International Conference on Intelligent Systems and Image Processing 2013*. 2013.
 - [24] Rosenblum, Michael, et al. "Phase synchronization: from theory to data analysis." *Handbook of biological physics*. Vol. 4. North-Holland, 2001. 279-321.
 - [25] Aoyagi, Toshio. "Network of neural oscillators for retrieving phase information." *Physical review letters* 74.20 (1995): 4075.

発表文献

- [1] Naoki, Toyoshima, and Takashi Kohno. "Decoding spike patterns of auto-associative memory on spiking neuronal networks", *Proceedings of International Conference on Artificial ALife and Robotics*. Vol. 2019. 2019.

付録 A 各種パラメータの値

表 2 DSSN モデルおよびシナプスのパラメータの値

Param.	class1	class2	class2(modified)	Param.	class1	class2	class2(modified)
a_n	8.0	8.0	8.0	a_p	8.0	8.0	8.0
b_n	0.25	0.25	0.25	b_p	0.25	0.25	0.25
c_n	0.5	0.5	0.5	c_p	0.5	0.5	0.5
k_n	2.0	4.0	3.125	k_p	16.0	16.0	12.5
p_n	-0.3125	-0.5625	-0.5625	p_p	-0.21875	-0.21875	-0.21875
q_n	-0.705795601	-1.317708517	-1.174186642	q_p	-0.6875	-0.6875	-0.681836382
ϕ	1.0	0.5	0.5	τ	0.003	0.003	0.003
r	-0.205357142	-0.104166	-0.104166	I_0	-0.205	-0.23	-0.23
α	83.3			β	333.3		

表 3 ヘブ学習のパラメータの値

Param.	A_+	A_-	τ_+	τ_-	W_{max}	W_{min}
Value	0.015625	0.01171875	0.01125	0.0225	1	-1

表 4 「同期度を高めるネットワーク」に関連するパラメータの値

Param.	A	B	C	D	E	F	G	K	L
Value	8.0	8.0	0.5	0.35	1.0	0.8	1.0	1.0	1.0

表 5 「同期度を高めるネットワーク」の各結合の箇所ごとの、シナプス電流のパラメータ α および β の値

Connection	α	β
original \rightarrow center	83.3	333.3
original \rightarrow reference	83.3	333.3
original \rightarrow delay	83.3	333.3
original \rightarrow inhibitory	83.3	200.0
delay \rightarrow inhibitory	83.3	250.0
reference \rightarrow inhibitory	83.3	333.3
inhibitory \rightarrow output	83.3	220.0
center \rightarrow output	83.3	500.0