

— 修士論文 —

Class I および II のスパイクニューロンモデルによる
連想記憶メモリ

Associative Memory with Class I and II Spiking Neuron Models

平成 27 年 2 月 5 日提出
指導教員 河野崇 准教授

東京大学大学院工学系研究科
電気系工学専攻

学籍番号 37-136436
氏名 大沢義佳

概要

本研究の目的は全結合連想記憶メモリにおいて、構成ニューロンが Class I と II による結果に差が出る理由を調べることである。

連想記憶メモリは入力パターンに似ている格納パターンを出力するメモリで、ニューラルネットワークの代表的な応用の一つとして Hopfield モデルから始まり、単純なニューロンモデルで構成されてきた。近年、スパイクニューロンを用いた連想記憶メモリが研究されている。

スパイクニューロンは定値刺激に対する発火周波数によってクラス分けされている。Class I は 0 に近い周波数から発火し始め、刺激が強くなると周波数が増える。Class II ではある周波数から発火し始め、刺激の強さにあまり影響を受けない。スパイクニューラルネットワークは主に Class I によって構成されてきたが、最近 Class II ニューロンの重要性が指摘されている。

Li らは DSSN モデルを用いて Class I と II の両方で連想記憶メモリを構成し、クラスごとの性能の違いを比較した。その結果は、Class II のほうが Class I よりも高いエラーからでも正しい格納パターンを出力することができることを示していた。

そこで、連想記憶メモリを構成するニューロンモデルをクラスの特性を考慮しながら変更し、性能を評価することで、Class II のほうが Class I よりも優れている理由を調べる。まず、Class II の波形多様性が寄与しているか調べるために、人工的に伝達物質放出時間を固定した。つぎに、膜電位のリセットが含まれる Izhikevich モデルを用いてクラスごとの性能を比較した。その結果から Class II の type2 の PRC が寄与しているか調べるために Izhikevich モデルのリセットパラメータを変更し、PRC の形を変えて性能を調べた。

結果、波形多様性と周波数特性では、Class II の性能を上げている様子は見られなかったが、PRC によって性能の向上がみられた。

これにより、スパイクニューロンによる連想記憶メモリを効果的に作るできるようになり、さらなるスパイクニューロンの活用が期待される。

目次

概要.....	1
第1章 序論.....	3
1.1 背景.....	3
1.2 ニューロン.....	3
1.3 スパイキングニューラルネットワーク.....	5
1.4 研究の目的.....	8
1.5 論文の構成.....	8
第2章 ニューロンクラス.....	9
2.1 分岐構造と周波数.....	9
2.2 波形.....	12
2.3 PRC.....	14
第3章 スパイキングニューロンモデル.....	16
3.1 様々なニューロンモデル.....	16
3.1.1 conductance-based モデル.....	16
3.1.2 I&F-based モデル.....	20
3.1.3 定性的モデル.....	21
3.2 Izhikevich モデル.....	25
3.3 DSSN モデル.....	27
第4章 Spiking Associative Memory モデル.....	29
4.1 ニューロン.....	29
4.2 シナプス.....	29
4.3 連想記憶メモリモデル.....	30
第5章 シミュレーション結果.....	35
5.1 DSSN モデル.....	35
5.2 Izhikevich モデル.....	39
第6章 まとめ.....	47
謝辞.....	48
参考文献.....	49
発表文献.....	50
付録.....	51

第1章 序論

1.1 背景

コンピュータの発展とともに、ニューラルネットワークを利用した研究が進められており、そのニューロンモデルは現実のニューロンとはかけ離れた形で画像認識や機械学習において進歩した。

一方、脳により近い情報処理を目指す試みもある。ここでは、スパイクニューロンモデルが用いられる。ここで、各ニューロンがとても複雑なふるまいをするため、スパイクニューロンモデルは定量的に忠実に再現しようとする、非常に複雑になる。さらに、ヒトの脳は数十億個のニューロンから構成されるといわれており、計算速度と消費電力の点から、そのまま再現することは現実的ではない。計算速度の問題は、モデルの単純さにかかわる。モデルを単純化することにより、ニューロンの活動の再現性が劣化する。どの程度単純化するかを考えなければならない。一方、消費電力の問題は専用ハードウェア化による解決が研究されている。効率よくハードウェアを利用しつつ、ニューロンの特性を活かしたモデルが望ましい。

ニューロンは、定値刺激を与えたときの周期発火の特性によって Class I と II にクラス分けされている。スパイクニューラルネットワークは、多くのニューロンを簡単に表現するために Class I のみに単純化されて構成されてきた。ニューロンクラスが情報処理に果たす役割を明らかにすることが、未だに謎の多い脳のメカニズムの理解へつながることが期待される。

1.2 ニューロン

神経系では、ニューロン同士の電気信号のやり取りによって情報処理が行われていると考えられている。


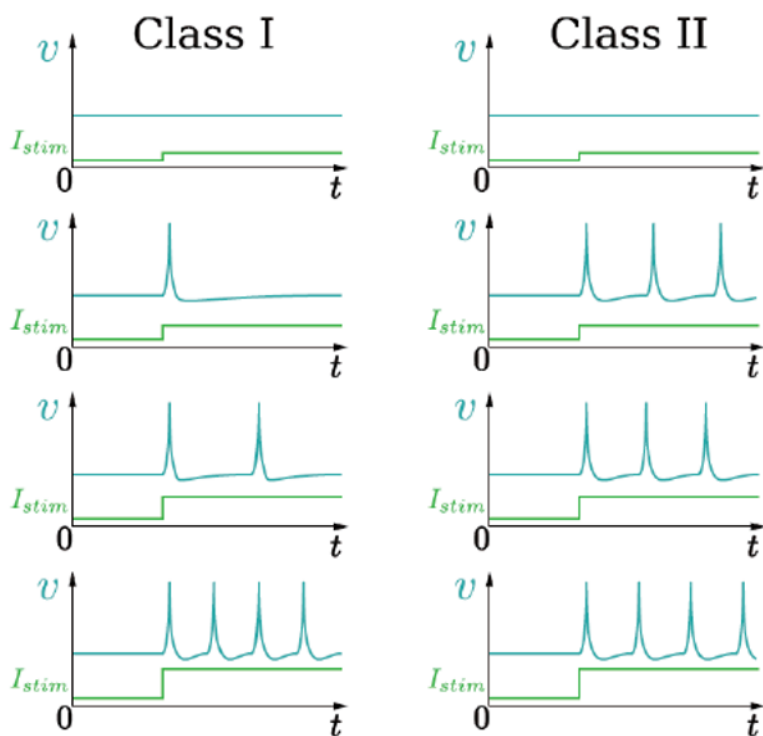


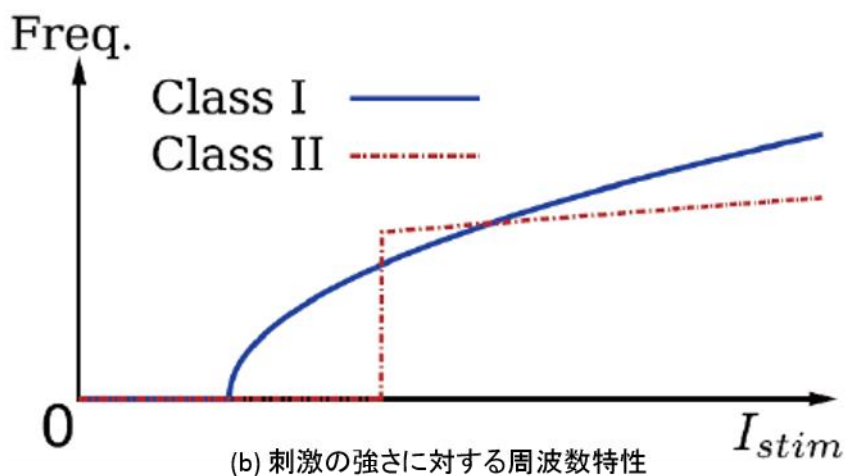
図 1.1 ニューロンの模式図と膜電位の模式図 [1]より引用

ニューロンはスパイク、不応期、周波数適応、バースト発火のような複雑なふるまいをする[1].

定値刺激によって周期発火するニューロンが存在する. この周期発火の周波数応答によって2つのクラスに分けられている[2]. Class Iは0に近い周波数から発火し始め, 刺激を強くすると周波数が高くなる. 一方, Class IIは, ある一定の周波数から始まり, 刺激の大きさにはあまり影響を受けない.



(a) 刺激の強さに対する膜電位の波形



(b) 刺激の強さに対する周波数特性

図 1.2 Class ごとの周期発火の模式図 [1]より引用


1.3 スパイクングニューラルネットワーク

ニューラルネットワークは、神経系で行われている情報処理を模倣して、一般的なコンピュータが苦手とされている複雑な問題を解決するために研究されている。ニューロンモデルをステップ関数やシグモイド関数を用いて利用されている人工ニューラルネットワークは画像認識や機械学習などで広く利用されている。一方、ニューロンのスパイクに着目したスパイクングニューラルネットワークには、蔵元らの位相振動子モデルを用いたネットワーク[3]もあるが、今回は神経ネットワークの電気活動をより詳しく再現できる定性的


モデルによるネットワークに着目する。

ニューラルネットワークのシミュレーションでは、高速な実装のためにハードウェアが利用されている。また、ニューロンモデルの単純化のために、クラスの違いは無視され、Class I ニューロンによるネットワークが作られてきた。しかし、近年、Class II ニューロンの役割が注目されている。

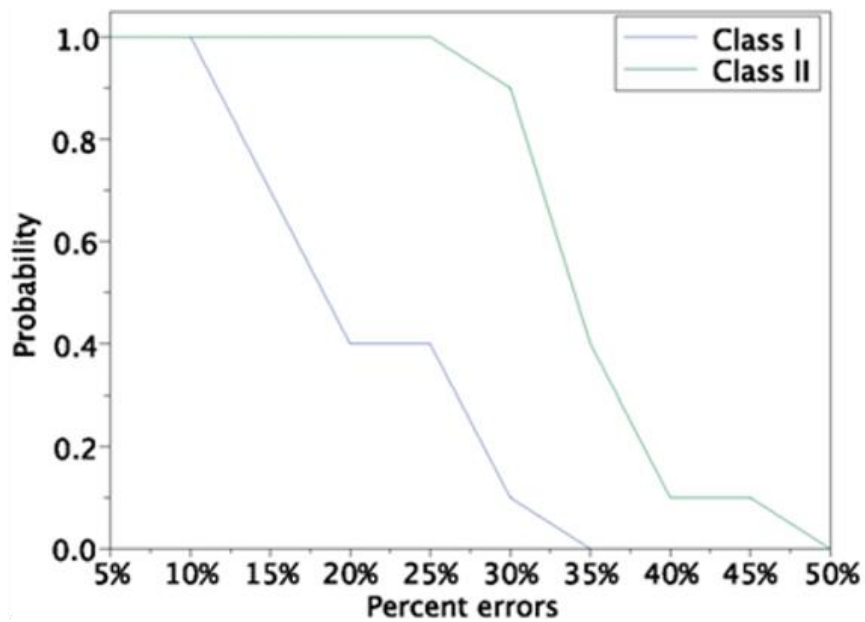
特に、今回は Li らの先行研究[4]に焦点を当てる。Li らは Digital Spiking Silicon Neuron (DSSN)モデルを用いて 256 ニューロンによる連想記憶メモリを構成した。連想記憶メモリは、入力パターンに似ている格納パターンを出力するメモリで、デジタルコンピュータによるメモリよりも高速な検索ができるといわれている。ニューラルネットワークの基本的な応用の一つで、性能の評価に利用される。この研究では、メモリに 4 つのパターンを相関学習によって学習させて格納し、各パターンにランダムエラーを付与したものを入力して格納パターンが正しく想起されるか検証した。クラスごとの結果を比較したところ、Class II のほうが高いエラーレートでも正しいパターンを出力することができることが示された。



(a) 格納パターン



(b) 入力パターン



(c) シミュレーション結果

図 1.3 先行研究の概略図 [4]から引用

1.4 研究の目的

本研究の目的は、先行研究で示されたニューロンのクラスの違いによって生じる連想記憶メモリの性能差について、そのメカニズムを調べることである。2つのクラスには周期発火の周波数の他にも特性の違いがいくつかある。それらの特性を抽出してネットワークを構成し、性能を評価していく。

1.5 論文の構成

第1章で序論を述べる。第2章ではニューロンモデルをいくつか挙げ、第3章では先行研究でも利用された連想記憶メモリモデルの詳細を紹介する。第4章ではクラスの違いによる特性の違いを示す。第5章で比較した特性ごとの連想記憶メモリシミュレーションの結果し、第6章で本論文のまとめを行う。

第2章 ニューロクラス

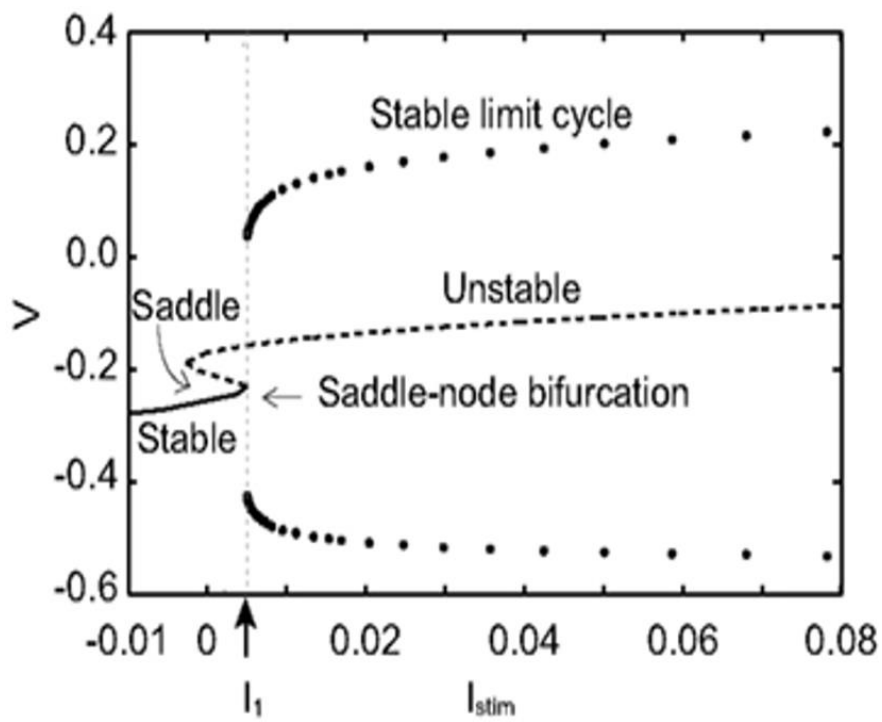
ニューロンのクラスは定値刺激に対する周期発火の周波数で分けられているが、他にもいくつか異なる特性がある。これらについて、先行研究で用いられた DSSN モデルを例にして着目する。

2.1 分岐構造と周波数

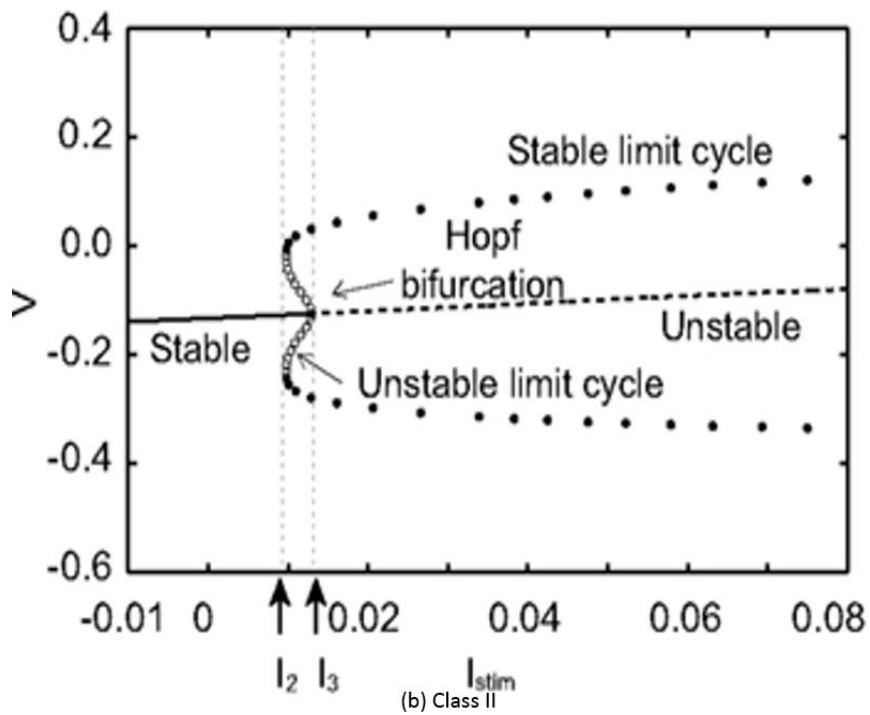
クラスの定義は定値刺激に対する周期発火の周波数で定義されるが、それぞれのクラスは位相平面にナルクライン構造や周期発火するときの分岐構造の違いが知られている。図 2.1 のように、Class I ではサドル・ノード分岐、Class II では Hopf 分岐が起こる。これは、位相平面解析からも説明される。

Class I ではナルクラインの交点が 3 つあり、それぞれ、安定平衡点(S)、鞍点(T)、不安定平衡点(U) である。刺激入力によって v ナルクラインが上昇すると、(S)と(T)が近づいていき、合体して消える。こうしてサドル・ノード分岐が起こり、周期発火が始まる。ここで Class I では、(T)の周囲には(T)に近づく安定多様体と、(T)から離れる不安定多様体があり、状態点の軌道はこれに沿って一度(T)に近づく。(T)の周辺では両変数の時間微分が小さいので周波数の低い周期発火が起こる。

一方 Class II の位相平面は、ナルクラインの交点が安定平衡点(S)の一つだけであり、刺激入力によって(S)が不安定平衡点(U)に変わる Hopf 分岐によって周期発火が起こる。Class II にはサドル・ノード分岐のような状態点の速度を低下させるメカニズムがないので、ある周波数からしか周期発火が起こらない。




(a) Class I




(b) Class II

図 2.1 分岐構造とクラス [4]より引用



(a) Class I



(b) Class II

図 2.2 位相平面とクラス [4]より引用

2.2 波形

クラスの違いは波形にも影響を与える。これも位相平面上の分岐構造の違いで説明できる。

Class I では、スパイクは、(T)の不安定多様体に沿って状態点が移動することによって発生するので刺激の強さにかかわらず **all-or-none** と呼ばれるようなスパイクの形が同じ形になりやすいという特徴がある。図 2.3(a)の波形からも膜電位の最大値やスパイク幅が比較的揃っている。

一方、Class II では、そのような軌道が存在せず、刺激の大きさに対してスパイク波形が変化する。波形を見ても、膜電位の最大値やスパイク幅に比較的大きなばらつきがみられる(図 2.3(b))。





図 2.3 クラスと波形 (DSSN モデル)

2.3 PRC

Phase Resetting Curve (PRC)は周期発火中のニューロンに対するパルス刺激タイミングと位相変化量のプロットである。




図 2.4 パルス刺激タイミングの違いによる波形の変化

PRC の横軸が刺激を与えたタイミングの位相で、縦軸が位相変化量である。各クラスの PRC は Class I はほとんど正のみ(type 1)である一方、Class II は正負両方の値をとる(type 2)。これも位相平面解析で説明できる。

PRC は、膜電位の上昇中に刺激を与えると正になりやすく、下降中に刺激を与えた場合は負になりやすい。

Class I では、膜電位の下降中の状態点の移動速度が、上昇中に比べて速いため、位相に変換したときに狭い範囲になる。そのため Class I では負の部分がほとんどない PRC になる(type 1)。

一方、Class II では下降中も上昇中も移動速度の差が比較的少ないため、正負両方の値をとる PRC になる(type 2)。





図 2.5 クラスと PRC

第3章 スパイキングニューロンモデル

スパイキングニューロンモデルは、ニューロンの膜電位変化を数式で表したものであり、スパイキングニューロンモデルは大きく 3 種類に分けられる。ニューロンの定量的なふるまいを詳細に記述する conductance-based モデル、状態変数のリセットでスパイクを表現する Integrate-and-Fire (I&F)-based モデル、数理構造を維持したまま conductance-based モデルの式を単純化した定性的モデルの 3 種類である。まず、それぞれについて代表的なモデルを紹介する。次に、連想記憶メモリにおいてクラスごとの性能を比較するためのシミュレーションにふさわしいモデルを 2 つ説明する。

3.1 様々なニューロンモデル

3.1.1 conductance-based モデル

まず、Conductance-based モデルの代表例である Hodgkin-Huxley モデルについて説明する[5]。このモデルは世界で最初の定量的な神経モデルであり、イカの巨大軸索の観測データから神経細胞内外のイオン濃度に着目することで導かれた。細胞膜をキャパシタと考えた膜電位と細胞膜を通過する電流の微分方程式になっており、ナトリウムイオンとカリウムイオン、膜電位に依存しないリーク電流をコンダクタンスに見立てている。各コンダクタンスはイオンチャンネルがどの程度開いているかによって決まり、イオンチャンネルはゲート粒子が全て開いているものだけが電流を通す。 m, h, n は各ゲート粒子の開いている割合を表しており、各アルファは開状態に遷移する確率とベータは閉状態に遷移する確率を表す。




図 3.1 細胞内外のイオン模式図 [1]より引用

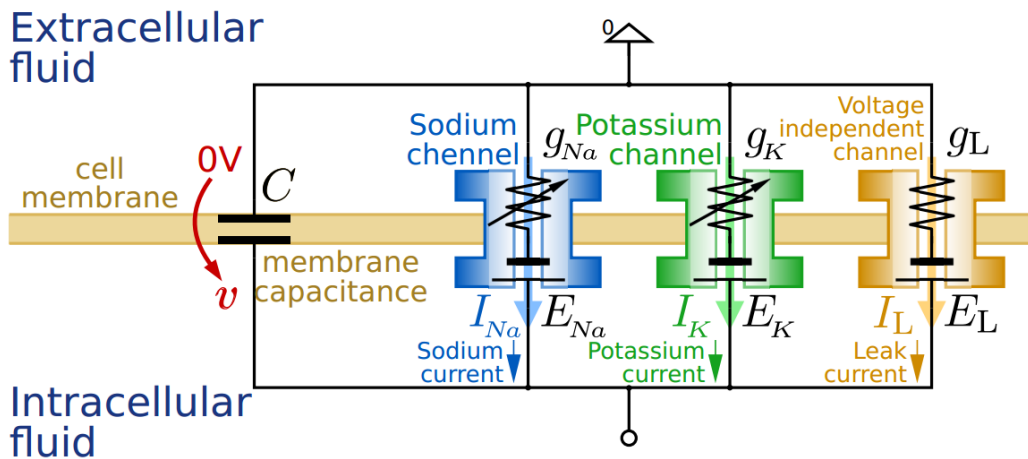


図 3.2 細胞膜の等価回路 [1]より引用

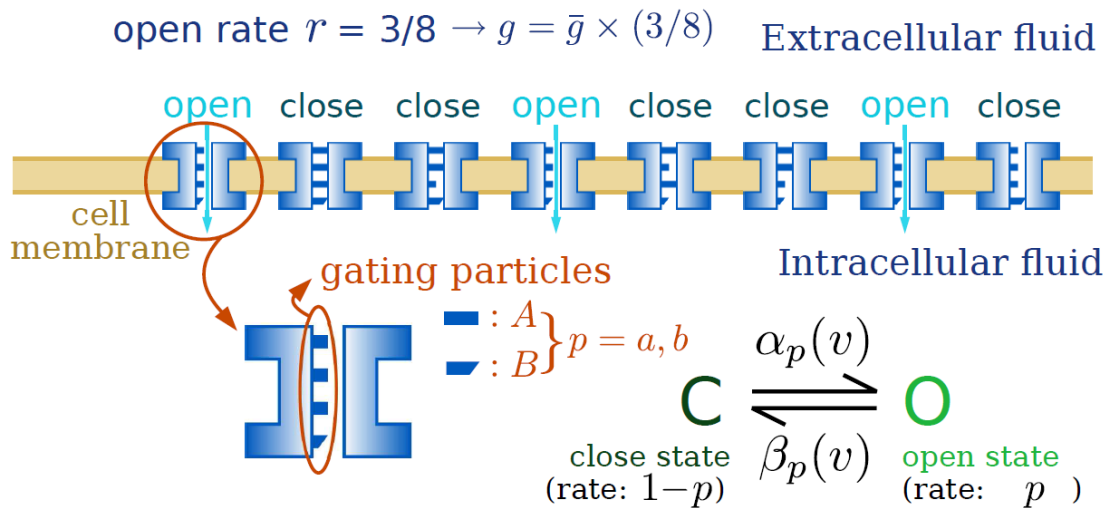


図 3.3 イオンチャネルの模式図 [1]より引用

$$C_m \frac{dv}{dt} = \bar{g}_{Na} m^3 h (E_{Na} - v) + \bar{g}_K n^4 (E_K - v) + \bar{g}_L (E_L - v)$$

$$\frac{dm}{dt} = \alpha_m - (\alpha_m + \beta_m)m \tag{3.1}$$

$$\frac{dh}{dt} = \alpha_h - (\alpha_h + \beta_h)h$$

$$\frac{dn}{dt} = \alpha_n - (\alpha_n + \beta_n)n$$

さらにこのアルファとベータは膜電位に依存し、非線形な実験データに合わせて指数関数によって表されている。Hodgkin-Huxley モデルでは、スパイク生成と閾値、一度目スパイクの後しばらくの間次の刺激入力に対してスパイク生成閾値が上昇する不応期、十分長い抑制値の刺激入力の後に正の入力を入れなくてもスパイクが起こる anodal break

excitation などの現象がみられる. Hodgkin-Huxley モデルは神経のスパイク現象をよく表現できるが, 4 変数の非線形な微分方程式は大規模なネットワークのシミュレーションに用いることは計算コストが莫大であり, 現実的ではない.

$$\begin{aligned}\alpha_m &= \frac{0.1(v + 40)}{1 - \exp(-(v + 40)/10)} \\ \beta_m &= 4\exp\left(-\frac{v + 65}{18}\right) \\ \alpha_h &= 0.07\exp\left(-\frac{v + 65}{20}\right) \\ \beta_h &= \frac{1}{1 + \exp(-(v + 35)/10)} \\ \alpha_n &= \frac{0.01(v + 55)}{1 - \exp(-(v + 55)/10)} \\ \beta_n &= 0.125\exp\left(-\frac{v + 65}{80}\right)\end{aligned}\tag{3.2}$$

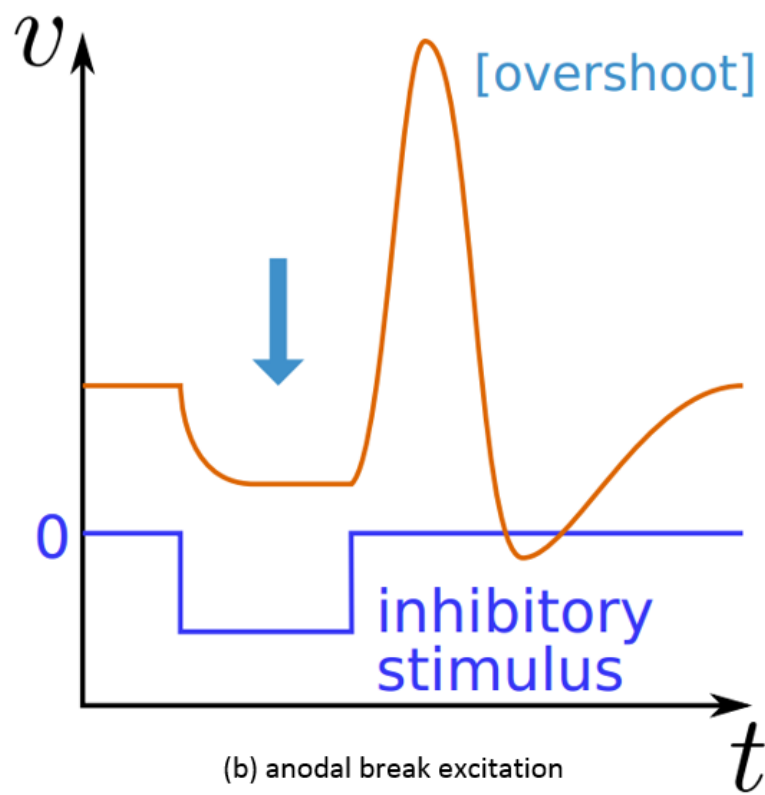



図 3.4 不応期と anodal break excitation の模式図 [1]より引用

3.1.2 I&F-based モデル

スパイク現象のような、ニューロンの重要と考えられる特性を再現することを目的とした I&F-based モデルがある。現象論的モデルの代表例が Leaky I&F (LIF)モデルである。LIF モデルは、1 変数の微分方程式で入力を積分して膜電位を計算し、閾値を超えたらスパイクが発生したとみなし、一定時間膜電位を静止膜電位 v_0 に固定することで不応期を再現している。しかし、I&F-based モデルは着目した特性が残っているだけで、神経活動のメカニズムを無視しているため、元の特性を無視している部分もある。例えば LIF モデルでは Class II が実現できず、anodal break excitation も見られない。

$$C \frac{dv}{dt} = -\frac{v}{R} + I_{in} \quad (3.3)$$

$$\text{if } v > \theta, v = v_0, \text{ for } \tau_{ref}$$

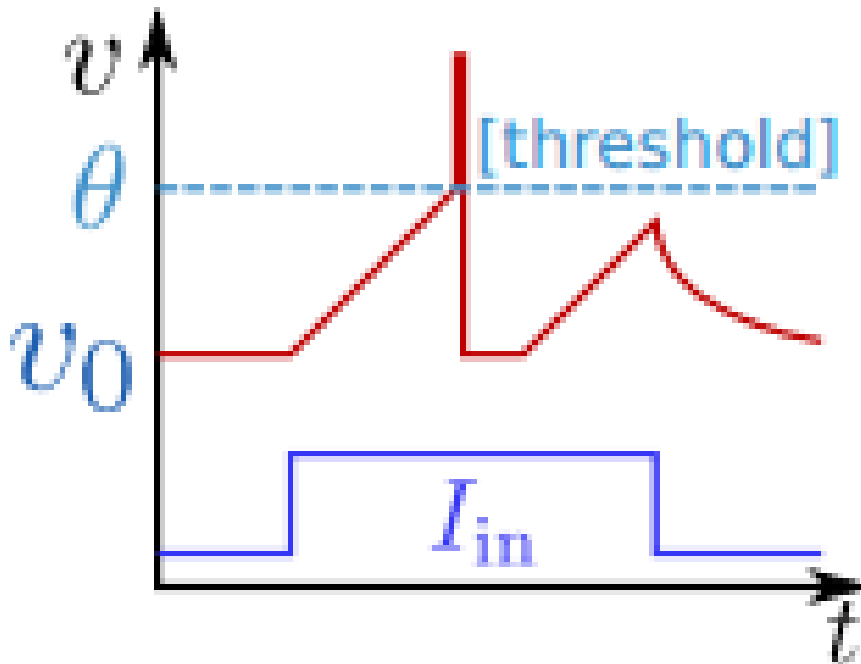


図 3.5 LIF モデルの波形模式図 [1]より引用

3.1.3 定性的モデル

定性的モデルでは、単純化された式で複雑な現象を表現するために、神経細胞のメカニズムを conductance-based モデルより簡単な式で記述している。FitzHugh-Nagumo モデル [6] は最初の定性的ニューロンモデルであり、Hodgkin-Huxley モデルの数理構造を保持したまま微分方程式を多項式で記述している。

$$\begin{aligned}\frac{dx}{dt} &= c\left(y + x - \frac{x^3}{3} + z\right) \\ \frac{dy}{dt} &= -\frac{x - a + by}{c}\end{aligned}\tag{3.4}$$

$$\left(1 - \frac{2}{3}b < a < 1, 0 < b < 1, b < c^2, c > 0\right)$$

x が膜電位、 y はイオンチャネルの活動、 z は刺激入力を表す。また、FitzHugh-Nagumo モデルは 2 変数で記述されており、不応期や Anodal break excitation などの現象も位相平面を用いて解析される。





図 3.6 FitzHugh-Nagumo モデルによる不応期と anodal break excitation の波形例
[1]より引用

位相平面は各変数を x 軸と y 軸とに割り当てた平面であり、 x の時間微分がゼロの点を青い x ナルクライン、 y の時間微分がゼロの点を赤い y ナルクラインであらわして、2 つナルクラインから各変数が次にどのように変化するか予想できる。例えば x ナルクラインより下では x の時間微分は負なので左へ移動する。逆に上では時間微分が正なので右へ移動する。同様に y ナルクラインより右では y は下に、左では y は上に状態を移動する。ナルクラインの交点は平衡点を表しており、刺激がなければ安定平衡点で(S)である。破線の部分で膜電位の上昇と下降が境目になっており、ここがスパイク生成の閾値としての役割を果たしている。

また、発火が起こって状態が周回している間は閾値が高くなっており、不応期のメカニズムが説明できる。継続的に負の入力が起こると x ナルクラインがさがり、安定平衡点が下に移動する。

入力が終わると状態の位置はすぐに安定平衡点には戻れないので、左に移動し始め、anodal break excitation が起こる。

膜電位のナルクラインが 3 次曲線で書かれていることが特徴である。




図 3.7 FitzHugh-Nagumo モデルの位相平面 [1]より引用

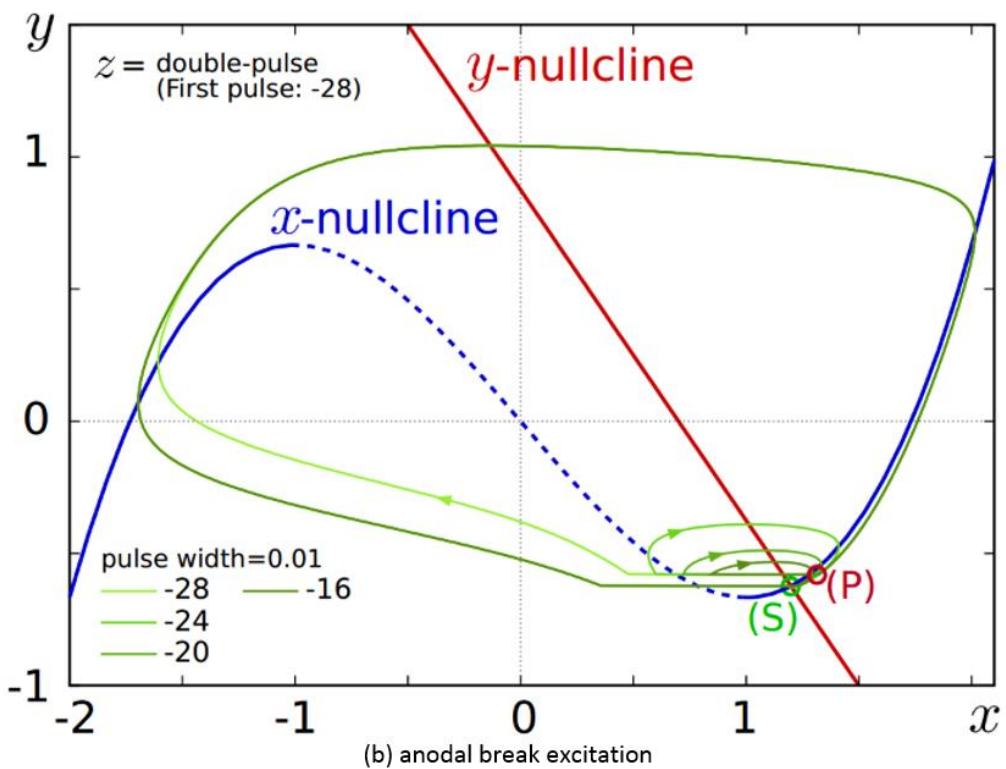
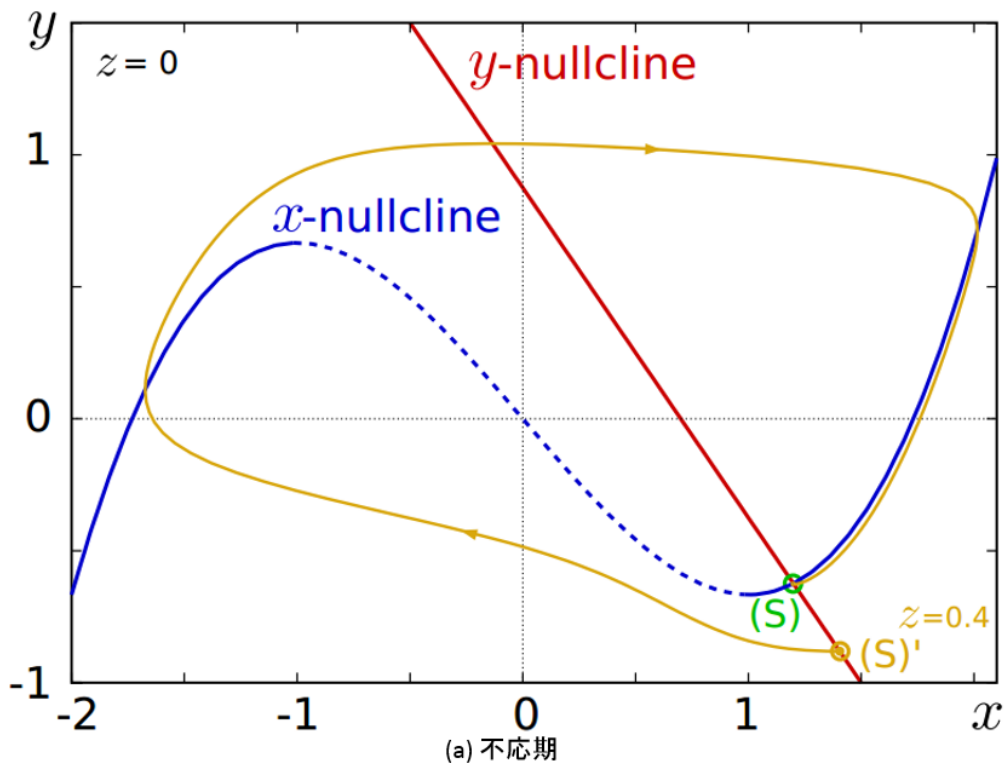


図 3.8 不応期と anodal break excitation の位相平面解析 [1]より引用

3.2 Izhikevich モデル

つづいて、大規模なニューラルネットワークのシミュレーションに適したモデルを紹介する。FitzHugh-Nagumo モデルは多項式に 3 次の項を含んでおり、デジタル回路では乗算は大きなリソースを必要としてしまう。スパイク決定プロセスにおけるメカニズムを保持したまま、膜電位のリセットを用いることで 2 次の多項式で記述したのが Izhikevich モデルである[7]。パラメータを調整することで Class I と II 両方の特性を得ることができ、他にも多様なバースト発火を生成できる。膜電位のリセットによってスパイクを表現しているので、Izhikevich モデルは現象論モデルと定性的モデルの中間に位置しているといえる。

$$\frac{dv}{dt} = 0.04v^2 + 5v + 140 - u + I$$

$$\frac{du}{dt} = a(bv - u) \tag{3.5}$$

if $v > 30$ then

$$v \leftarrow c$$

$$u \leftarrow u + d$$





図 3.9 Izhikevich モデルの位相平面

3.3 DSSN モデル

場合分けを用いることで、膜電位のリセットを行わずに、2 次の多項式からなる微分方程式で記述したのが DSSN モデルである [8]. Izhikevich モデル同様、パラメータにより Class I と II の両方が再現できる. 赤の線が膜電位を表す v のナルクライン、緑の線が抽象化されたイオンの活動度を表す n のナルクラインである. 二次曲線の組み合わせで 3 次曲線のような膜電位のナルクラインを表現している. Li らのシミュレーションも DSSN モデルを用いて行われた.


$$\frac{dv}{dt} = \frac{\varphi}{\tau} (f(v) - n + I_0 + I_{stim})$$

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

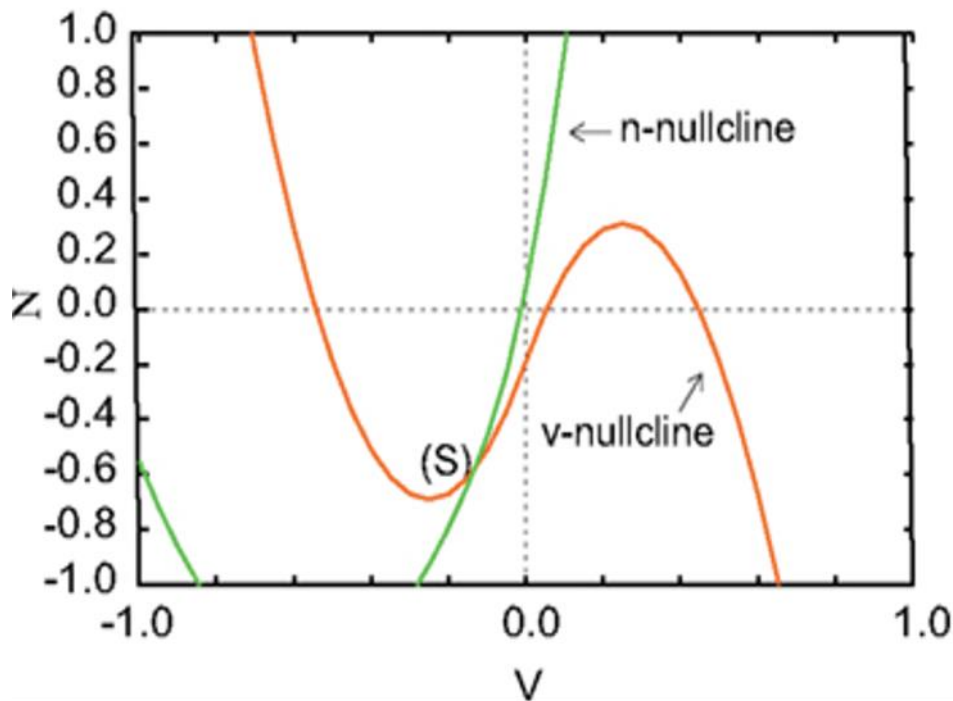
where

(3.6)

$$f(v) = \begin{cases} a_n(v + b_n)^2 - c_n & (v < 0) \\ -a_p(v - b_p)^2 + c_p & (v \geq 0) \end{cases}$$
$$g(v) = \begin{cases} k_n(v - p_n)^2 + q_n & (v < r) \\ k_p(v - p_p)^2 + q_p & (v \geq r) \end{cases}$$



(a) Class I



(b) Class II

図 3.10 DSSN モデルの位相平面 [4]より引用

第4章 Spiking Associative Memory モデル

この章では, Li らの先行研究で用いられた Spiking Associative Memory モデルについて説明する. 連想記憶メモリモデルは, ネットワークを構成するニューロンモデルとシナプス, さらにこれらを包含する連想記憶メモリモデルからなる.

4.1 ニューロン

ニューロン数 N は $N=256$ 個で, 各ニューロンには順番に 1~256 の番号がふられている. 先行研究では, DSSN モデル(2.3)が用いられた. DSSN モデルのパラメータは付録の表 1 に示す.

4.2 シナプス




図 4.1 シナプスの模式図 [1]より引用

次にシナプスについて考える. シナプスとはニューロン間の電氣的なやり取りを担うものであり, 化学シナプスでは, 一つのニューロンが発火すると, 付随するシナプスから神経伝達物質が放出され, 別のニューロンへの入力となる. 化学シナプスのキネティックモデルを単純化したシナプスモデルの式は, 以下の式のようになる[9].


$$\frac{dI_s}{dt} = \begin{cases} \alpha(1 - I_s) & ([T] = 1) \\ -\beta I_s & ([T] = 0) \end{cases} \quad (4.1)$$

ニューロンの膜電位が閾値を超えると神経伝達物質の濃度 $[T]$ が 1 になり, シナプス電流が増える. V が閾値を下回ると $[T]$ が 0 になりシナプス電流は下がる.


この I_s が次のニューロンに伝わるが, シナプスの伝達は入出力の対象によって効率が変わり, これが学習や記憶のメカニズムであると考えられている.

$$I_{stim}^i = c \sum_{j=1}^N W_{ij} I_s^j \quad (4.2)$$


この式では W_{ij} であらわされて次のニューロンの入力になる. 今回, シナプスは 256×256 個で構成される.



(a) 膜電位の時間変化



(b) 伝達物質濃度の時間変化



(c) シナプス出力の時間変化

図 4.2 膜電位, 伝達物質濃度, シナプス出力の例

4.3 連想記憶メモリモデル

続いて, 連想記憶メモリモデルについて説明する. メモリには 256 ビットのバイナリパターンを 4 つ格納させる. パターンの先頭から順番に 1~256 の番号が付けられ, 同じ番号のニューロンに対応する. u 番目のパターンの i 番目のビット x_i^u は $x_i^u \in \{1, -1\}$ となる. 1 を黒, -1 を白として視覚化すると図 3.3 のようになる.




図 4.3 格納パターン [3]より引用

シナプスの重みは相関学習で計算される.

$$W_{ij} = \begin{cases} \sum_{u=1}^{P=4} x_i^u x_j^u & (i \neq j) \\ 0 & (i = j) \end{cases} \quad (4.3)$$

入力パターンには, 格納パターンにエラーとしてランダムでビットを選んで反転させたものを与える. エラー率は5~50%まで5%ごとに設定されている.






図 4.4 入力パターンの例 [3]より引用

想起プロセスは, まずパターンの黒に対応するニューロンにのみ刺激を与える. 与える値は Class I では 0.125, Class II では 0.0425, 時間は 16.875ms とする. 続いてすべてのニューロンに, 周期発火を引き起こす定値刺激を与える. 値は Class I で 0.074, Class II で 0.0295 とする.



(a) 膜電位の波形



(b) ラスタープロット

図 4.5 想起中の波形とラスタープロット

図 4.5(a)はパターン 1 を基に 5%のエラーを入力したときの膜電位の波形で, (b)はそのラスタプロットである. ラスタプロットとは, 各ニューロンが閾値を超えた時間をプロットしたものである. 線の色はパターン位置の色に対応しており, 青が黒, 赤が白に対応している. 最初の刺激を与えた段階では比較的バラバラに発火しているが, 発火を繰り返していくと, 発火タイミングが揃っていくのが分かる. 白と黒に対応するニューロンはそれぞれ逆相で発火する.

これを定量的に評価するためにオーバーラップ M_u を用いる[10]. オーバーラップは各ニューロンの位相とパターンの一致具合を表す.

$$\phi_j(t) = 2\pi k + 2\pi \frac{t - t_j^k}{t_j^{k+1} - t_j^k} \quad (4.4)$$

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

ここで t^k は j 番目のニューロンが k 回目に発火した時間を表す. $M_u = 1$ になると, 位相が u 番目のパターンと一致していることを意味する.




図 4.6 オーバーラップの時間経過の例

図 4.6 は図 4.5 の例のオーバーラップである. 青線(M_1)が 1 になっている. この結果はパターン 1 が正しく想起されたことを意味する.

実際にこのモデルを用いて, 得られた結果は以下のようになり, Class II のほうが Class I より高いエラーから正しいパターンを出力できる.




図 4.7 先行研究の結果 [3]より引用

第5章 シミュレーション結果

各特性を抽出してモデルを操作してシミュレーションを行った。

5.1 DSSN モデル

まず, Li らの先行研究と異なる DSSN パラメータでも Class II の高性能が見られるか調べた。付録の表 2 に示すパラメータを用いた。

このパラメータを用いた連想記憶メモリの結果は図 5.1 のようになる。




図 5.1 DSSN パラメータを変更した場合の結果

この結果から, DSSN パラメータに依存せず, Class II の特性により, 高いエラーからでも正しいパターンを出力できると考えられる。

波形の多様性と連想記憶メモリの性能の関係を調べるために, Class II のニューロンとシナプスの間にスパイク持続時間を固定する波形整形器を取り入れたネットワークを構成した。波形整形を行わない場合は, 波形の多様性によってスパイク持続時間が変わり, シナプス電流の大きさが変わることでアナログの情報を伝達している可能性がある。波形整形を行うことで, 波形の多様性があるスパイク持続時間を同じにして, シナプス電流の大きさが変わらないようにした。

図 5.2 のようにどんな波形のスパイクに対してもシナプス電流は変わらない。

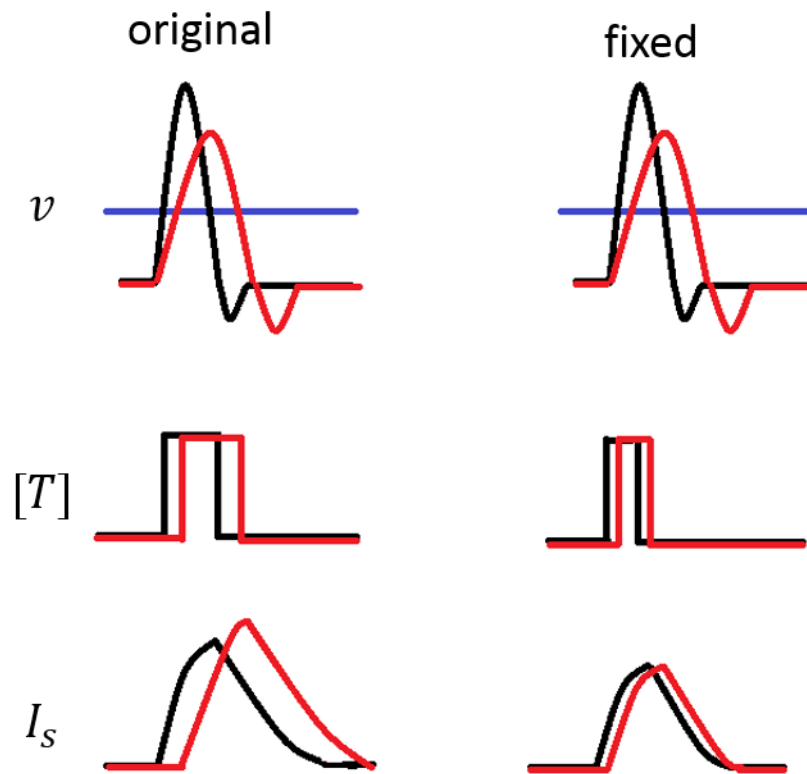



図 5.2 波形整形器の模式図

DSSN パラメータは 5.1 のものを用いた. 伝達物質放出時間は 1ms ごとに 1~10ms で固定した. 結果は図 5.3 のようになった.




図 5.3 波形整形器つき連想記憶メモリの性能

この結果から、伝達物質放出時間を固定しても高い性能が示されており、伝達物質放出時間の多様性が連想記憶メモリの性能に寄与しているとはいえない。

DSSN モデルではスパイク後の値が指定されないので、前のスパイクの影響を次のスパイクに残すことができる。このことが Class II ニューロンの性能向上に寄与しているのではないかと考えた。想起中の変数のリターンマップを記録した(図 5.4)。

エラーが増えるにつれてプロットのばらつきが多くなっている。しかし、性能と前のスパイクの影響を関連付けられたとはいえない。

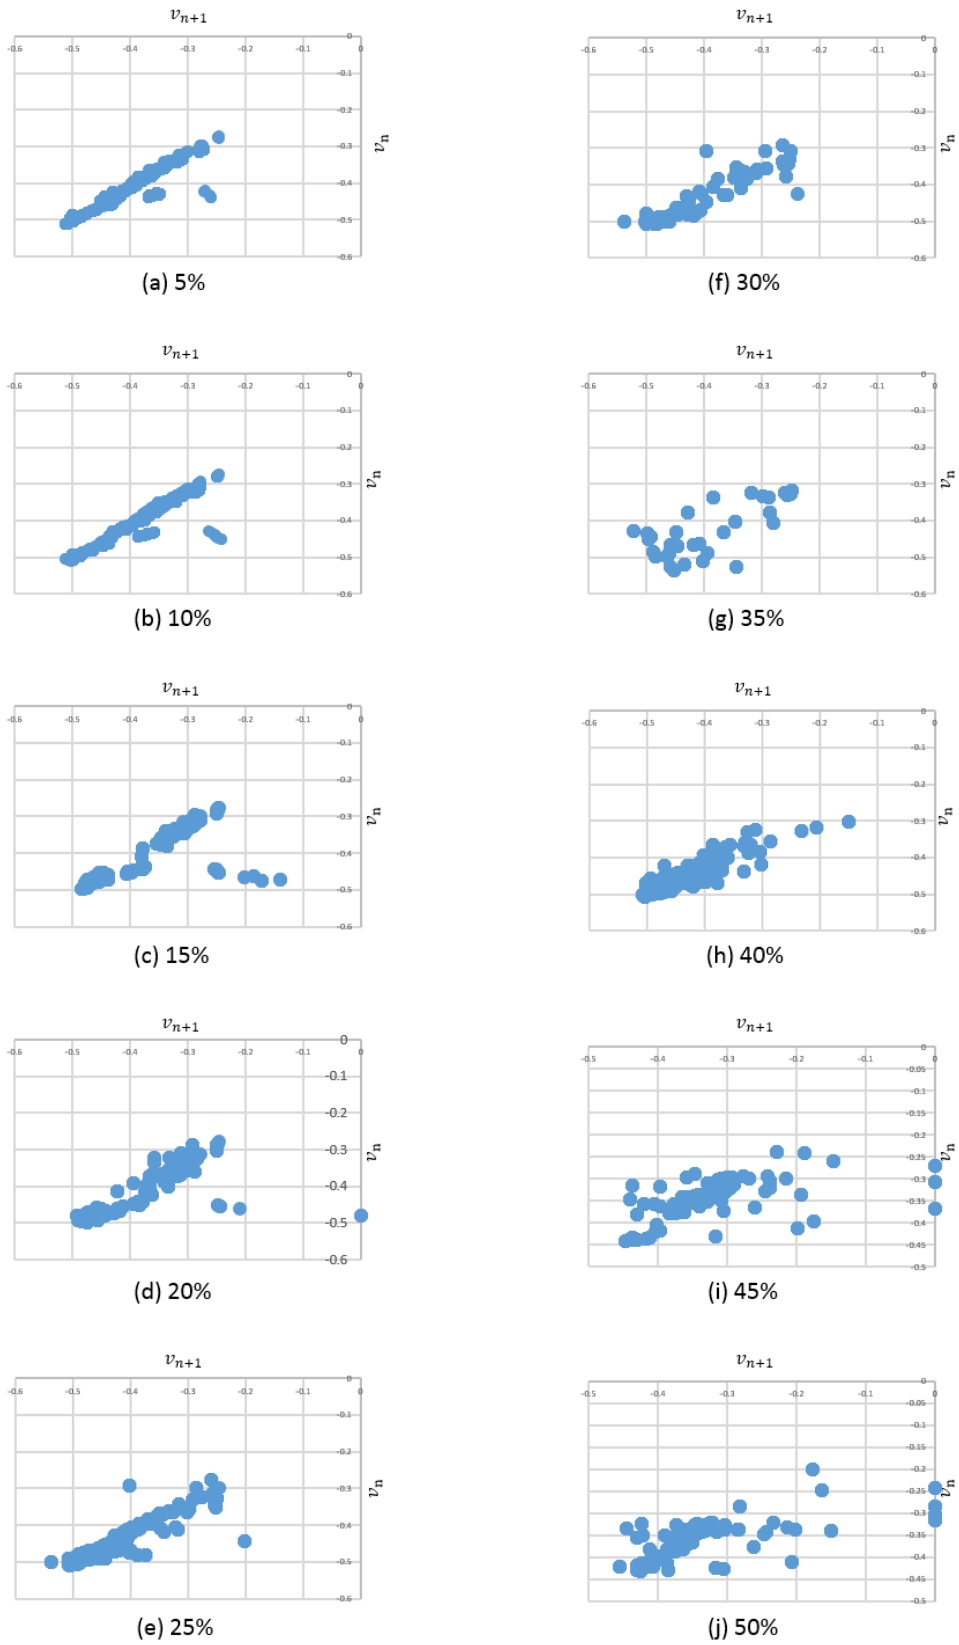



図 5.4 $n=-0.5$ を通過するときの v の値のリターンマップ


5.2 Izhikevich モデル

Izhikevich モデルを利用することで、周期発火時の周波数が連想記憶メモリの性能を左右するのか調べた。

パラメータは[7]で指定された値を用いた(付録表 3)。各クラスの波形、周波数は図 5.5, 図 5.6 に示す。




(a) Class I




(b) Class II

図 5.5 Izhikevich モデルの波形



(a) Class I



(b) Class II

図 5.6 Izhikevich モデルの発火周波数

Izhikevich モデルの連想記憶メモリの性能は図 5.7 のようになる.




図 5.7 Izhikevich モデルの連想記憶メモリの性能

上記シミュレーションで用いた Izhikevich モデルの PRC を調べてみると図 5.5 のようになり, Class II でも type 1 のように見える.




図 5.8 Izhikevich モデル Class II の PRC

位相平面解析に基づき PRC の形を type 2 にした. c は静止膜電位のため固定し, d を変更

した.




図 5.9 d と位相平面






図 5.10 d と PRC

d を 0 から 200 まで 20 ずつ変化させた連想記憶メモリの性能は図 5.11.



(a) エラー5%ごと



(b) エラー1%ごと

図 5.11 d の変化と連想記憶メモリの性能

PRC と連想記憶メモリの性能が関係しており、PRC の負の部分が重要であると考えられる。

同様のことが動的シナプスでも起こるか調べた。ヘブ則を用いた。式は、

$$\Delta W = K_a(W)K_i(W)[A_+ \exp\left(-\frac{|\Delta t|}{\tau_+}\right) - A_- \exp\left(-\frac{|\Delta t|}{\tau_-}\right)]$$

$$K_a(W) = \frac{W_{max} - W}{W_{max} - W_{min}} \quad (5.1)$$

$$K_i(W) = \frac{W - W_{min}}{W_{max} - W_{min}}$$

を用いた。用いた d とパラメータは、付録表 4 に示す。





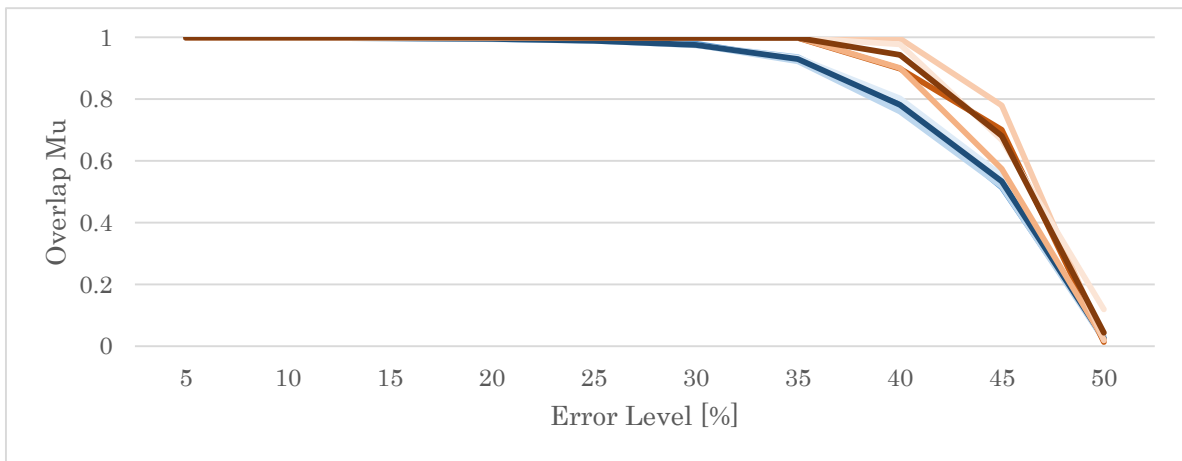
図 5.12 ヘブ則の学習窓関数

d ごとに相関学習と比較した性能は図 5.13. ヘブ則でも同様の結果が見られた.

$d = 0$



$d = 20$



$d = 120$




図 5.13 学習則ごとの連想記憶メモリの性能

第6章 まとめ

本研究は、スパイクングニューラルネットワークによる連想記憶メモリにおいて、ネットワークを構成するニューロンのクラスに着目し、性能の違いが生まれる理由を調べるために、クラスごとの特性の差を抽出したネットワークを構成して、性能の比較を行った。まず、先行研究で用いられた DSSN モデルに伝達物質放出時間を固定したシナプスモデルを付随しても性能は下がらなかった。一方、膜電位のリセットが含まれている Izhikevich モデルを用いた連想記憶メモリでは、Class II の性能が低かった。DSSN モデルと Izhikevich モデルの間には、Class II の PRC の違いがあり、リセットパラメータ d を変更して、PRC を近づけたところ、連想記憶メモリの性能が高くなった。

このことから、PRC の形の違いが連想記憶メモリの性能に影響していると考えられる。今後は PRC の形を定量的に表した位相モデルによりネットワークを構成することで確かめられると思われる。また、ヘブ則のシミュレーションをより詳細に行う必要がある。

謝辞

本研究に際して、丁寧なご指導をいただきました、河野先生に深く感謝いたします。また、研究のアドバイスや様々な協力をしてくださった合原研究室の職員の皆様、先輩、同期、後輩に感謝いたします。

参考文献

- [1] T. Kohno, "SIGNAL TRANSMISSION IN NEURONS", 6.188. Mathematical Physiology, Unesco Encyclopedia of Life Support Systems, 2011.
- [2] Hodgkin, A. L. "The local electric changes associated with repetitive action in a non-medullated axon," J. Physiol. 107, 165-181, 1948.
- [3] Aoyagi, T, Aoki, T. "Possible role of synchronous input spike trains in controlling the function of neural networks," Neurocomput.58-60, 259-264, 2004.
- [4] Jing Li, Yuichi Katori, Takashi Kohno, "An FPGA-Based Silicon Neuronal Network with Selectable Excitability Silicon Neurons", Frontiers in neuroscience 6 183, 2012.
- [5] Hodgkin A. L., Huxley A. F., "A quantitative description of membrane current and its application to conduction and excitation in nerve", J. Physiol. 117, 500-544, 1952.
- [6] FitzHugh R. "Impulses and physiological states in theoretical models of nerve membrane," Biophysical Journal 1(6), 445-466, 1961.
- [7] Izhikevich, E. M.. "Dynamical Systems in Neuroscience: The Geometry of Excitability and Bursting," Cambridge: MIT Press, 2006.
- [8] Kohno, T., and Aihara, K. "Digital spiking silicon neuron: concept and behaviors in GJ-coupled network," in Proceedings of International Symposium on Artificial Life and Robotics, Beppu, OS3-OS6, 2007.
- [9] Destexhe, A., Mainen, Z. F., and Sejnowski, T. J. "Kinetic models of synaptic transmission," in Methods in Neuronal Modeling, eds C. Koch and I. Segev Cambridge, MIT Press, 1-25, 1998.
- [10] Domany, E., and Orland, H. "A maximum overlap neural network for pattern recognition," Phys. Lett. 125, 3234, 1987.

発表文献

- [1] Yoshika OSAWA, "Analysis of Associative Memory with DSSN model", The 1ST International Symposium on Neuromorphic and Nonlinear Engineering, 2014.
- [2] Y. Osawa and T. Kohno, "Associative Memory with Class I and II Izhikevich Model", The International Conference on Artificial Life and Robotics 2015

付録

Par.	Class I	Class II	Par.	Class I	Class II
a_n	8	8	a_p	8	8
b_n	0.25	0.25	b_p	0.25	0.25
c_n	0.5	0.5	c_p	0.5	0.5
k_n	2	4	k_p	16	16
p_n	-0.3125	-0.5625	p_p	-0.21875	-0.21875
q_n	-0.705795601	-1.317708517	q_p	-0.6875	-0.6875
φ	1	0.5	τ	0.003	0.003
r	-0.205357142	-0.104166	I_0	-0.205	-0.23

表 1: DSSN モデルのパラメータ

Par.	Class II	Par.	Class II
a_n	8	a_p	8
b_n	0.25	b_p	0.25
c_n	0.5	c_p	0.5
k_n	4	k_p	16
p_n	-0.5625	p_p	-0.21875
q_n	-1.317708517	q_p	-0.6875
φ	0.5	τ	0.003
r	-0.104166	I_0	-0.23

表 2 新しい DSSN Class II パラメータ

Par.	Class I	Class II
a	0.02	0.2
b	-0.1	0.26
c	-55	-65
d	6	0

表 3 Izhikevich モデルのパラメータ

Par.	d=0	d=20	d=120
A_+	0.0625	0.0625	0.0625
A_-	0.046875	0.046875	0.046875
τ_+	5	6.25	8
τ_-	8	12	16

表 4 ヘブ則に用いたパラメータ