

平成 29 年度

修士学位論文

スパイキングニューラルネットワークを
用いた物体軌道予測

Object Trajectory Prediction
Using Spiking Neural Network

1205077 梅寄 佑樹

指導教員 岩田 誠

平成 30 年 2 月 28 日

高知工科大学大学院 工学研究科 基盤工学専攻
情報システム工学コース

要旨

スパイクングニューラルネットワークを用いた物体軌道予測

梅寄 佑樹

近年, ANN(Artificial Neural Network) の研究が進み, DNN(Deep Neural Network) が注目を集めている. しかし, 従来の DNN では時系列データの処理が難しい. RNN(Recurrent Neural Network) は時系列データを扱うことができるが離散化されたものに限る. 連続時間における時系列データの処理を目的として BNN(Biological Neural Network) の要素を含む DyBM などの SNN(Spiking Neural Network) も開発されている. だが, 扱う情報が 2 値であるため, スパイクタイミングの情報が省かれ, 任意のタイミングでの入力に対応することができず, ロバスト性を持たないという欠点を持つ.

そこで, 本研究では, SSA-BM(Single Spike Axon Boltzmann Machine) を提案した. 提案モデルは, STDP(Spike Timing Dependent Plasticity) 型学習が可能な LAF(Leaky Integrate and Fire) モデルニューロンからなる完全結合 RNN に対して, 単一スパイクのみを許す軸索機能, および, 最速反応型出力デコーダを新たに加えたモデルである.

提案モデルを動画内物体軌道予測課題を用いて, 正常な入力を与えた場合の予測率と, 入力に微小な時間的揺らぎや欠損といった例外が含まれる場合に対するロバスト性という点で評価した. その結果, 学習済みの動画に対する高い予測率と例外を含む入力に対するロバスト性を持つことがわかった.

今後の課題としては, 複数の物体軌道パターンに対しての予測を可能にすることと, より大きなフレームサイズ, フレーム数の動画に対して応用可能にすることが挙げられる.

キーワード SSA-BM, DyBM, STDP, LAF モデル

Abstract

Object Trajectory Prediction Using Spiking Neural Network

Yuki UMEZAKI

In recent years, research on artificial neural network(ANN) has progressed, and deep neural network(DNN) attracts attention. However, it is difficult for conventional DNN to process time series data. Recurrent neural network(RNN) can handle discretized time series data. Spiking neural network(SNN) such as DyBM including elements of Biological neural network(BNN) have also been developed for the purpose of processing time series data in continuous time. However, since DyBM handles only binary data, information on spike timing is omitted. Therefore, it can not deal with input at an arbitrary timing and has the drawback on the robustness.

In this study, we proposed Single Spike Axon Boltzmann Machine(SSA-BM). The proposed model is structured by a perfectly connection RNN consisting of leaky integrate and fire(LAF) model neurons that perform learning using the mechanism of spike timing dependent plasticity(STDP). And, SSA-BM has the Axonal function to allow only a single spike and the fastest response type output decoder. The prediction rate when normal input was given was evaluated, and the robustness against illegal timing frame or frame loss is evaluated. As a result, SSA-BM achieve high prediction rate for learned frame sequence and robustness against exceptions at input sequence.

key words SSA-BM, DyBM, STDP, LAF model neuron

目次

第 1 章	序論	1
第 2 章	神経回路網モデル	9
2.1	緒言	9
2.2	Lealy Integrate and Fire(LAF) モデル	9
2.3	Boltzmann Machine	12
2.4	DyBM(Dynamic Boltzmann Machine)	14
2.5	スパイクコーディング方法	15
2.6	結言	16
第 3 章	SSA-BM(Single Spike Axon Boltzmann Machine)	20
3.1	緒言	20
3.2	SSA-BM(Single Spike Axon Boltzmann Machine) の構成	20
3.2.1	ニューロンの動作	22
3.2.2	スパイク信号のコーディング・デコーディング	24
3.2.3	軸索の構成	28
	遅延 FIFO キュー	29
	Spike Prop 構造	30
3.3	結言	30
第 4 章	評価	33
4.1	緒言	33
4.2	性能評価	33
4.2.1	評価条件	33
4.2.2	正常な入力時系列パターンに対する予測率と必要な学習回数	35

目次

4.2.3	例外を含む入力時系列パターンが与えられた場合のロバスト性	36
4.3	結言	38
第 5 章	結論	42
	謝辞	48
	参考文献	49

目次

1.1	実際のニューロン [3]	2
1.2	パーセプトロン型のニューラルネットワークの例	4
1.3	ホップフィールド型のニューラルネットワークの例	5
2.1	LAF モデルにおけるスパイク信号のシナプス電流	11
2.2	LAF モデルにおけるスパイク信号の α 関数による変換結果	11
2.3	スパイク信号が連続して到着した場合のニューロンの処理	12
2.4	LAF モデルにおける V_m の時間的变化例	12
2.5	Boltzmann Machine の構成	13
2.6	従来のスパイクコーディングの例	18
2.7	SSA-BM で用いるスパイクコーディング方法	19
3.1	SSA-BM(Single Spike Axon Boltzmann Machine) の構成	21
3.2	Neural eligibility trace と Synaptic eligibility trace	24
3.3	SSA-BM の情報の流れ方の例	25
3.4	学習時の入力データのエンコード例	26
3.5	テスト時の入力データのエンコード例	27
3.6	学習時の SSA 部のスパイク信号変換の例	28
3.7	テスト時の SSA 部のスパイク信号変換の例	29
3.8	学習時のスパイク信号のデコード例	30
3.9	テスト時のスパイク信号のデコード例	31
3.10	SSA-BM のニューロン間の結合	32
4.1	規則的な物体軌道の条件	34
4.2	規則的な物体軌道の例	39

図目次

4.3	不規則的な物体軌道の例	40
4.4	学習時とテスト時の入力パターン例	41

表目次

4.1 LAF モデルのパラメタ	35
4.2 物体軌道予測率と学習回数 (正常な前半フレーム入力時)	36
4.3 物体軌道予測率 (例外フレーム入力時)	37

第 1 章

序論

近年，ニューラルネットワークに関する先行研究の成功例が数多く発表されている。Google の先行研究 [1] では，YouTube の動画から無作為に取り出した画像 1000 万枚を学習データとして用い，3 日間ディープラーニングを行った。その結果，学習したニューラルネットワークは猫の顔を認識することが可能となった。また，Google DeepMind 社が開発したコンピュータ囲碁プログラムである AlphaGo が囲碁の世界トップ棋士に勝利し話題になったのも記憶に新しい。

元々は，これらの人工神経回路網 ANN (Artificial Neural Network) は，生物の神経細胞ネットワークの働きを簡略化したモデルを計算機上で模倣することによって，最適化問題や認識課題に応用する目的で開発された。一方で，生物の神経細胞ネットワークがどのように働いているかを科学的に解明する，BNN(Biological Neural Network) に関する研究も進められてきた。

BNN のシミュレーションモデルに関する研究 [2] は，動物の脳を忠実に計算機上で再現することを目的としている。動物の脳細胞であるニューロンは図 1.1 の様に，細胞体，樹状突起，軸索，シナプスから成る。

ニューロンは複数の他のニューロンとつながっており，ニューロン間の信号伝達はスパイク信号によって行われる。あるニューロンが膜電位の変化によって発火を起こすと，細胞体から軸索，シナプスへとスパイク信号が伝達され，次のニューロンへスパイク信号が送られる。次のニューロンは複数の他のニューロンから送られてきたスパイク信号の影響を受け，膜電位を変化させ，更に次のニューロンへスパイク信号を送る。ニューロンの膜電位の変化の要因はスパイク信号による入力電流と，膜電流と呼ばれる細胞内のリーク電流が主

である。膜電流は K^+ と Na^+ が大きく関わっており、イオンチャンネルと呼ばれる開閉するイオンの出入り口を K^+ と Na^+ が通ることで膜電位が変化する。これらの電流によって膜電位が閾値に達するとニューロンは発火を起こし、スパイク信号を生成する。その後、膜電位は安静時膜電位と呼ばれる電位まで下がり、不応期と呼ばれる一定時間発火の起こらない状態へと移行する。ニューロン同士をつなぐシナプス結合部分では、スパイク信号が電流として直接伝達されるのではなく、前ニューロンのシナプス前終末による神経伝達物質放出と、後ニューロンのシナプス後終末の神経伝達物質結合、それによるイオンチャンネルの解放という形で信号伝達が行われる。また、シナプスにはシナプス強度と呼ばれるものが存在し、シナプス強度により伝達信号に強弱や興奮性、抑制性といった補正が掛けられる。BNN のシミュレーションモデルとしては代表的な、発火率 (Firing Rate) モデル、積分発火 LAF(Leaky Integrate and Fire) モデル、Hodgkin-Huxley モデル、マルチコンパートメントモデルの 4 つが挙げられる。この 4 つのシミュレーションモデルはどれも先に説明したようなニューロンの処理をモデル化している。発火率モデルはニューロンの発火頻度に重きを置き、発火頻度とシナプス強度を再現している。LAF モデルは発火率モデルに加え、膜電位の変化やスパイク信号の到着タイミングの差異等も再現している。Hodgkin-Huxley モデルは膜電流の K^+ と Na^+ の働きの違いを計算に含めており、マルチコンパートメントモデルはニューロン内の部位ごとの膜電位の差異さえも再現している。この様に、BNN の




図 1.1 実際のニューロン [3]

シミュレーションモデルはそれぞれ精度は違うが、ニューロンの動作を数理的に表現している。これらのニューロンモデルのシミュレーションには膨大な演算量を必要とし、従来、汎用型コンピュータでは実用的な時間でシミュレーション結果を得るのが難しかった。だが、近年では、計算機の性能が向上したことで、スーパーコンピュータではより大規模で正確なニューロンのシミュレーションを行うことが可能となり、スーパーコンピュータ等を使用せずともシミュレーションモデルの種類や規模を選ぶことでコモデティコンピュータでもシミュレーションが可能となってきている。

ANN に関する研究は、ニューラルネットワークを活用して実用的に役に立つ技術を開発することを目的している。ANN は一般的にヘブ則と呼ばれる学習則によって実際のニューロンで言うところのシナプス強度となる重みを変化させ、問題解決能力を持たせる。ANN には大きく分けてパーセプトロン型とホップフィールド型のネットワーク形態が存在する。パーセプトロン型は図 1.2 のように、基本的に情報が一方向に伝搬されるネットワーク形態である。一方、ホップフィールド型は図 1.3 のように、情報が相互に伝搬されるネットワーク形態である。

ネットワークの代表的な例としては、パーセプトロン型のニューラルネットワークは FNN(Feedforward Neural Network) や AE(AutoEncoder), RNN(Recurrent Neural Network) 等が挙げられ、ホップフィールド型のニューラルネットワークの例としてはボルツマンマシン (Boltzmann Machine) が挙げられる [4]。近年では、これらのホップフィールド型のニューラルネットワークを応用した、3 層より多層なニューラルネットワークである DNN(Deep Neural Network) が注目を集めている。従来のパーセプトロン型のニューラルネットワークでは、多層でネットワークを構築した場合、期待されるような結果を得ることが難しかった。しかし、DNN を用いたディープラーニングでは、特徴抽出を目的とした層と、類別を目的とした層に分けて事前学習を行うことで、従来のニューラルネットワークと比較すると多入力かつ精度の高い学習を行えることが判ってきた。また、DNN 以外にも RNN やボルツマンマシンのような、与えられた入力データに対して、それまでの入力データによって変化させたニューロンやネットワークの状態を踏まえた出力データを返すような

ニューラルネットワークも注目を集めている。これらは、前入力データに対する処理結果を再び入力として取ることで、入力を受け取る以前までの情報を踏まえた処理結果を出すことができ、言語翻訳などに応用されている。例として挙げたニューラルネットワークはどれも BNN の様にニューロン間で伝達する信号がスパイク信号ではなく、発火率にあたる数値で信号伝達を行っている。すなわち、ニューロン内の膜電位の変化などは計算しておらず、BNN と比較すると神経細胞の計算処理の大部分を抽象化し省いていると言える。

これらの2つのニューラルネットワークに関する研究は今まであまり交わることが少なく、それぞれ独立して研究が進められてきた。と言うのも、先に述べたように BNN は脳の忠実な再現を目的としており、神経細胞生物学の分野として研究が進められてきたが、ANN は技術開発を目的としており、IT の分野として研究が進められてきたからであると考えられる。しかしながら、近年では、計算機の性能が向上したことで BNN のニューロンモデルのシミュレーションが比較的容易になったこと、ANN の研究が進みこれまで解くことができなかった難解な課題を解くことができる DNN や時系列によって変化する課題を解くこと




図 1.2 パーセプトロン型のニューラルネットワークの例




図 1.3 ホップフィールド型のニューラルネットワークの例

ができるニューラルネットワークが登場したことから、BNN のシミュレーションモデルと ANN を組み合わせたニューラルネットワークの研究が盛んになってきている。

BNN のシミュレーションモデル、もしくはそれを簡略化したモデルを用いたニューラルネットワークはスパイク信号を用いて情報の伝播を行うため、SNN(Spiking Neural Network) と呼ばれる [5][9]。SNN の例として、IBM 社が発表した DyBM(Dynamic Boltzmann Machine) が挙げられる [6]。これは、BNN のシミュレーションモデルを簡略化したものとボルツマンマシンを組み合わせた SNN であり、時系列パターンを記憶することが可能である。DyBM は過去の入力データを踏まえた出力を返すことが可能なボルツマンマシンと、スパイク信号を用いた学習則である STDP(Spike Timing Dependent Plasticity) を組み合わせることで、時系列パターンの記憶を可能にし、学習した時系列パターンの前半数パターンを入力として与えれば残りは入力を与えずとも時系列パターンを出力することができる。しかし、この DyBM はニューロンの動作を離散的にシミュレーションしており、シミュレーションタイミングにおけるスパイク信号の扱いは受け取ったか否か、もしくは発火したか否かの 0-1 の処理である。そのため、外部からの入力信号が学習時の時系列パターンに対して

多少前後するような、任意のタイミングで入力信号が与えられる時系列パターンに対しての対応ができない。また、任意のタイミングで入力信号が与えられる時系列パターンに対応するために学習時の時系列パターンを時間窓の概念で拡張した場合、入力時系列パターンが数倍になってしまい、学習が困難になってしまうという欠点を持つ。これにより、学習時の時系列パターンと比べて、離散シミュレーションのタイミングとタイミングの間にあるパターンが与えられる可能性のある場合や、与えられた時系列パターンに抜け落ちが発生する可能性がある場合課題に対して応用が難しい。近年、高フレームレート化が進む動画への応用や、動画のフレーム内のピクセルの変化量に応じてフレームレートが動的に変化する ATIS カメラなどへの応用を考えた場合、先に述べたような欠点は大きな問題となる。

そこで、再帰構造を持つニューラルネットワークに BNN を導入し、高精度で離散事象シミュレーションすることで、時空間的パターンの学習及び予測が可能になり、時間的誤差や抜け落ちを持つ入力パターンに対してロバストな処理が可能になるのではないかと考えた。

本研究では、再帰構造を持つ ANN に BNN を導入したニューラルネットワークの実装及びその性能評価を行った。再帰構造をもつ ANN として DyBM を参考にボルツマンマシンを選択し、BNN として LAF モデルを選択した。ボルツマンマシンは、過去の入力データを含めた処理が可能であり、また、2 値により情報を伝播するため、スパイク信号を情報伝播に用いる LAF モデルのニューロンと相性が良いと言える。LAF モデルを選択した理由は、ANN と近い BNN のシミュレーションモデルである発火率モデルと比較するとより神経細胞の再現度が高く、かつ他の更に再現度の高いモデルと比較すると実装が容易で計算量も少ないからである。

本研究では、STDP 型学習が可能な LAF モデルニューロンからなる完全結合 RNN に対して、単一スパイクのみを許す軸索機能、および、最速反応型出力デコーダを新たに加えたニューラルネットワークである SSA-BM(Single Spike Axon Boltzmann Machine) を提案する。これは、再帰構造をもつニューラルネットワークであるボルツマンマシンに LAF モデルのニューロンを導入した、従来のニューラルネットワークよりも実際の神経細胞の動きに近い処理を行い、時間的誤差や抜け落ちを持つ入力パターンに対してロバストな処理が可

能なニューラルネットワークである。提案する SSA-BM に対しての評価は動画内の物体の軌道予測に関して行い、物体が規則的に動く場合と不規則的 (ランダム) に動く場合に関して、それぞれ学習・予測能力と学習時の入力パターンと比較して時間的誤差や抜け落ちのを持つ入力パターンに対するロバスト性を評価する。

まず、第 2 章では、本研究で使用しているニューラルネットワークである積分発火 LAF モデルのニューロンを用いたニューラルネットワークの処理に関して述べる。特に、膜電位計算やスパイク信号による情報伝播など、LAF モデルのニューロンの主な特徴とその動作をどのように再現しているのかについて述べる。その後、再帰構造を持つホップフィールド型のニューラルネットワークであるボルツマンマシンの主要な動作に関して述べ、ボルツマンマシンに SNN の要素を動作したニューラルネットワークである DyBM に関して説明する。また、本研究で提案する SSA-BM に用いるスパイクコーディング方法についても述べる。従来のスパイクコーディング方法をいくつか例として挙げ、SSA-BM の構造や扱う課題から満たすべきコーディング方法の条件を考察し、新たに考え導入したコーディング方法について説明する。

第 3 章では、STDP 型学習が可能な LAF モデルニューロンからなる完全結合 RNN に対して、単一スパイクのみを許す軸索機能、および、最速反応型出力デコーダを新たに加えたニューラルネットワークである提案ニューラルネットワーク SSA-BM の構成方法について述べる。SSA-BM の全体的な構造や、情報の変換方法などについて述べる。特に情報の変換方法は、学習時とテスト時で扱いが異なるため、比較しながら説明を行う。

第 4 章では、第 3 章で述べた SSA-BM の性能評価を行う。性能の評価は動画内の物体軌道予測を用いて行う。評価は、まず動画内の物体の軌道を学習し、予測することが可能かを評価した後、入力する時系列パターンに学習した時系列パターンと比べて時間的誤差がある場合と、フレームの抜け落ちが存在した場合の、2 つの場合に対しても正しく物体の軌道予測が可能であるかどうか、つまり時間的誤差と抜け落ちに対してロバスト性を持つか否かを評価する。学習させる物体軌道パターンは規則的な軌道を取るものと不規則的な軌道を取るものを用意し、また、動画のフレーム数に関しても複数パターン用意する。

最後に，第 5 章では，提案した SSA-BM を構成・評価した本研究の結果に関して述べ，更にそれに対する考察を行う．また，その考察から今後の課題および展望を述べる．

第 2 章

神経回路網モデル

2.1 緒言

本章では、本研究で使用しているニューラルネットワークの説明を行う。まず、BNN のニューロンシミュレーションモデルの一つである積分発火 LAF モデルのニューロン内の膜電位の計算やスパイク信号の処理などに関して説明する。その後、ANN の一つでホップフィールド型のニューラルネットワークであるボルツマンマシンに関して説明する。また、既存のボルツマンマシンを用いた SNN である DyBM に関して説明する。最後にスパイクコーディング方法について述べる。

2.2 Leaky Integrate and Fire(LAF) モデル

BNN(Biological Neural Network) のニューロンシミュレーションモデルとしては代表的な、発火率 (Firing Rate) モデル、積分発火 LAF(Leaky Integrate and Fire) モデル、Hodgkin-Huxley モデル、マルチコンパートメントモデルの 4 つが挙げられる。

本論文で対象とする LAF モデルは、複数ある BNN のニューロンモデルの中でも特にシンプルなニューロンモデルである。LAF モデルは SNN(Spiking Neural Network) と呼ばれるニューラルネットワークの一種で、ニューロン間の信号伝達をスパイク信号によって行うニューラルネットワークである。LAF モデルはニューロンの膜電位の時間的变化やスパイク信号の到着タイミングの差異等をモデルに取り入れているのが特徴であり、シミュレーションソフト NEST[7] でもベンチマークとして扱われている。LAF モデルにおけるニュー

2.2 Leaky Integrate and Fire(LAF) モデル

ロンの膜電位の計算は、計算式 dV_m/dt によって表される。 dV_m/dt の計算式は以下の式 2.1 のようになる。

$$dV_m/dt = -(V_m - E_L)/\tau_m + I_{syn}(t)/C_m + I_e/C_m \quad (2.1)$$

V_m はシミュレーション時間 $t - 1$ における膜電位を表しており、 E_L は安静時膜電位を表している。 τ_m は膜時定数を表しており、 C_m は細胞膜の電気容量、 I_e は膜電流を表している。 $I_{syn}(t)$ は他のニューロンからのスパイク信号によるシナプス電流を α 関数で求めた後、その電流値の和を求めたものである。 $I_{syn}(t)$ 関数、および α 関数の計算式はそれぞれ以下の式 2.2 と式 3.2 のようになる。

$$I_{syn}(t) = w_{ij} \sum_{k=1}^n \alpha(t - t_j) \quad (2.2)$$

$$\alpha(t) = e^{-t/\tau_s} \times e^{((-t/\tau_s))} \times Heaviside(t) \quad (2.3)$$

式 2.2 における w_{ij} は i 番目のニューロンの j 番目のニューロンに対するシナプス強度を表しており、 t_j は j 番目のスパイク信号が到着した時刻を表している。式 3.2 における e は指数関数を表しており、 τ_s は α 関数による電流値が最大になるまでの時間を表している。 $Heaviside(t)$ はヘヴィサイドの階段関数を表している。

LAF モデルにおけるスパイク信号とそのスパイク信号が α 関数によってシナプス電流に変換された結果のグラフを図 3.3, 図 2.2 に示す。図 3.3 の様にスパイク信号が時間 t に到着したとすると、そのスパイク信号は α 関数によって図 2.2 の様にニューロン内で演算されることとなる。ニューロンは一般的に複数の他のニューロンと繋がっている。そのため、スパイク信号が短い間隔で連続して到着する場合は考えられる。図 2.3 のように、2つのニューロンから短い間隔で信号が到着した場合、それぞれスパイク信号を受け取ったニューロン内で α 関数によって変換され、その結果に重みをかけられて足しあわされる。これによって、受け取り側のニューロン内の膜電位が変化する。膜電位が閾値を超えていた場合、発火が起こり受け取り側の次のニューロンへとスパイク信号が伝達される。その後、膜電位が安静時膜電位へ低下し、一定時間の不応期へ移行する。図 2.4 は LAF におけ

2.2 Leaky Integrate and Fire(LAF) モデル

るニューロンの膜電位の時間的変化の例である。LAF モデルは発火後の膜電位の変化は省略されているため、膜電位が閾値に達し発火が起きた直後に安静時膜電位へ降下する。




図 2.1 LAF モデルにおけるスパイク信号のシナプス電流




図 2.2 LAF モデルにおけるスパイク信号の α 関数による変換結果

2.3 Boltzmann Machine




図 2.3 スパイク信号が連続して到着した場合のニューロンの処理




図 2.4 LAF モデルにおける V_m の時間的変化例

2.3 Boltzmann Machine

ボルツマンマシン (Boltzmann Machine) は入力データとネットワークの内部状態の組み合わせを効率的に検索できるように設計されたホップフィールド型のニューラルネットワークである。ボルツマンマシンは図 2.5 のように、ネットワーク内の各ニューロンが相互に結合しており、それぞれの結合に重みを持つ。ニューロン間の結合はあるニューロンから他のニューロンへ対してのみだけではなく、自分自身への結合、つまりリカレント構造の結合を

2.3 Boltzmann Machine

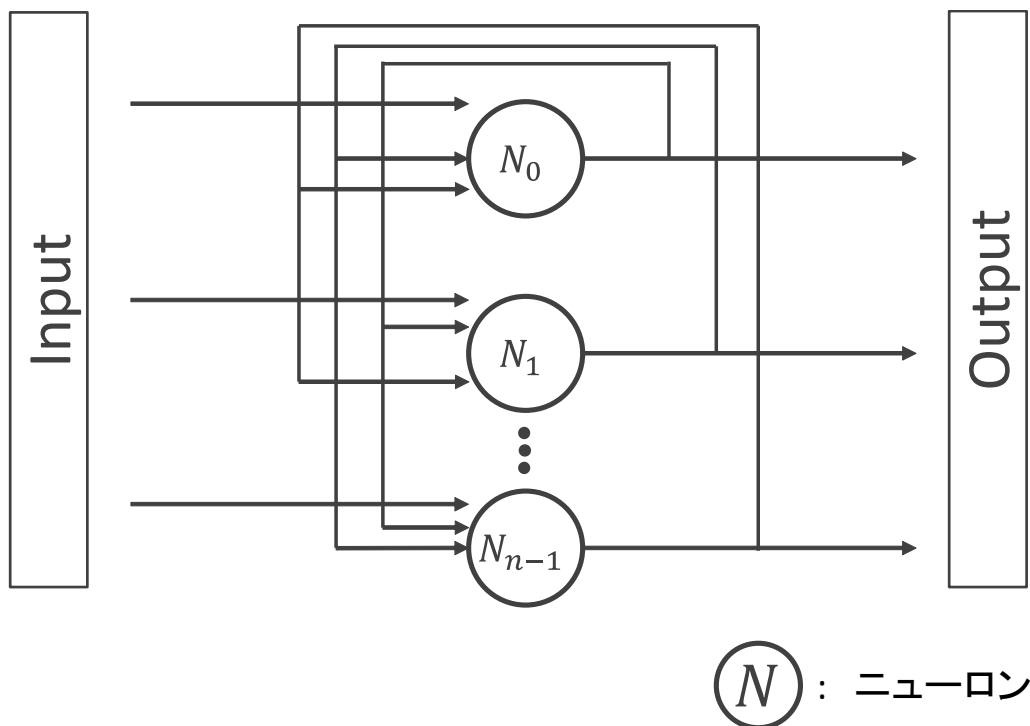


図 2.5 Boltzmann Machine の構成

持つものもある。ボルツマンマシンは情報を真と偽 (1 と 0) の 2 進数で伝播する。外部から入力を受け取ったニューロンはニューロンの状態を表すエネルギーを変化させ、その変化から自身が伝播する信号が真と偽のどちらであるかの確率を求め、その確率に従い情報を伝播する。ニューロンの状態が外部から入力を受け取る度に変化するため、過去の入力を踏まえた出力を返すことが可能である。また、ボルツマンマシンの特徴としてネットワーク全体の持つ温度が挙げられる。温度を高く設定するほど、出力の真偽を決める確率は曖昧になり、逆に温度を低く設定するほど明確になる。以下、ボルツマンマシンの主要な動作の説明をする。

外部から入力を受け取ったニューロンの持つエネルギー E は式 2.4 で表される。

$$E = -\frac{1}{2} \sum_{ij} w_{ij} s_i s_j - \sum_i (\eta_i - \theta_i) s_i \quad (2.4)$$

ここで、 i, j はそれぞれ i 番目のニューロン、 j 番目のニューロンを表し、 s は 0 か 1 かの値を取る。 η_i はニューロン i への外部からの入力を表し、 w_{ij} はニューロン i とニューロ

2.4 DyBM(Dynamic Boltzmann Machine)

ン j 間の重みを表し, θ_i はしきい値を表す.

また, このあるニューロン k が真または偽の値をとることによりもたらされるトータルエネルギーの差 ΔE_k は式 2.5 で表される.

$$\Delta E_k = \sum_i w_k s_i + \eta_k - \theta_k \quad (2.5)$$

この ΔE_k は真と偽の 2 つのエネルギー状態の差であるため, 式 2.6 と表すこともできる.

$$\Delta E_k = E_{false} - E_{true} \quad (2.6)$$

ΔE_k を用いて式 2.7 からニューロンが真を出力する確率を表す P_k を計算する.

$$P_k = \frac{1}{1 + e^{-\frac{\Delta E_k}{T}}} \quad (2.7)$$

ここで, $T(> 0)$ は BM のネットワーク全体の温度を表す. 温度 T が低くなるほど式 2.7 は 0 付近で傾きが急になり, 高くなるほどなだらかになる. $T \rightarrow 0$ では, ΔE_k が正か負かのみで P_k の値が 0.0 か 1.0 が決まるようになり, 逆に $T \rightarrow \infty$ では, ΔE_k の値によらず常に P_k は 0.5 となる.

このように, ボルツマンマシンは外部からの入力と現在のニューロンの状態から伝播値を確率的に決定し動作するニューラルネットワークである.

2.4 DyBM(Dynamic Boltzmann Machine)

DyBM(Dynamic Boltzmann Machine) は IBM 社が発表したボルツマンマシンに SNN の要素を導入したニューラルネットワークである [6]. ボルツマンマシンが伝播する真偽の情報をスパイク信号として扱い, ニューロンが真を出力する確率が 0.5 以上になった場合に発火した, そうでない場合を発火しなかったとみなしている. スパイク信号を扱うにあたって, 重みの学習方法に STDP(Spike Timing Dependent Plasticity) を採用し, シナプス前ニューロンからのスパイク信号の到着タイミングとシナプス後ニューロンの発火タイミングを考慮した学習を行っている. また, 各ニューロン間には FIFO(First in First out) 構

2.5 スパイクコーディング方法

造の遅延キューを持っており、シナプス前ニューロンの発火後、ランダムで設定された遅延キューの長さ分遅延してシナプス後ニューロンにスパイク信号が到着する。到着したスパイク信号は到着したタイミングだけでなく、永続的にシナプス後ニューロンに影響を与え続ける。影響量は徐々に減少する。各ニューロン間の結合は1つではなく複数存在しており、それぞれに異なる重みを学習する Spike Prop の構造を取る。この DyBM の最大の特徴は時系列パターンを記憶することが可能であるという点であり、そのために、ある時刻 t における外部からの入力データに対する出力が次の時刻 $t+1$ の入力データと等しくなるように学習を行う。この学習を繰り返すことで、入力の時系列パターンを全て与えなくとも出力として学習した時系列パターンを全て出力することが可能となる。

ここで述べた STDP や Spike Prop などの各要素は、本研究で提案する SSA-BM でも取り入れているため、次章でまとめて説明する。

2.5 スパイクコーディング方法

SNN で用いられるスパイク信号のコーディング方法は、例として図 2.6 などが挙げられる。図 2.6 の $n1$, $n2$, $n3$ はそれぞれニューロンを表し、各ニューロンが発火して生成・伝播したスパイク信号が右に示されている。stimulus は外部からの刺激 (入力スパイク信号) を示している。以下、例として上げたスパイクコーディング方法の特徴について述べ、本研究で用いた新たなコーディング方法の説明を行う。

図 2.6 の Single spike coding は時間窓内に 1 回以下の発火を許すスパイクコーディング方法である。時間窓の開始時刻からスパイク信号到着時刻までの遅延量 Δt を情報とする。2.4 節で説明した DyBM はこの Single spike coding から Δt の情報を省略し、スパイク信号が常に時間窓の開始時刻に到着する、もしくは時間窓内にスパイク信号がない、という 2 値にしたものであると考えることができる。Firing rate coding は時間窓内でニューロンが何度の発火を起こしたかを情報とするコーディング方法である。スパイク信号の到着時刻などは考慮していないコーディング方法であり、SNN ではない従来のニューラルネットワーク

2.6 結言

の情報伝播はこのコーディング方法と近いと言える。Time to first spike は外部からの刺激の到着時刻とニューロンからの最初のスパイク信号の到着時刻を情報とする。Rank-order coding はスパイク信号の到着順番を情報とする。Latency code は各スパイク信号の到着時間の差を情報とする。Phase coding はスパイク列をパルス位相で情報をコーディングする。

本研究では、ボルツマンマシンに LAF モデルのニューロンを導入し、任意のタイミングの入力に対応可能なネットワークを提案する。そのため、スパイク信号の到着時刻が重要な情報となる。任意のタイミングで入力を受け付けるため、スパイク信号到着の遅延量を、時間窓開始時刻からとするよりも入力スパイク信号が到着した時刻からとすべきである。更に、伝播するスパイク信号は扱う課題の性質上、複数のニューロンから生成されたものである必要があり、また、高速化を図るためスパイク信号は単一であることが好ましい。これらの条件より、従来のスパイクコーディング方法ではなく、図 2.7 のようなコーディング方法を用いることにした。

本研究で用いるコーディング方法は、図 2.7 のように入力スパイク信号の到着時刻 Δt とスパイク信号の有無を情報として扱う。各ニューロンが発火をすると各ニューロンの生成したスパイク信号の中で、入力スパイク信号到着後に最速で発火したタイミングのスパイク群のみを情報として出力し、他のスパイク信号は伝播しない。提案する SSA-BM 内でどのようにこのコーディング方法を用いてスパイク信号を扱っているかは次章にて述べる。


2.6 結言

本章では、本研究で使用しているニューラルネットワークの説明を行った。BNN のニューロンシミュレーションモデルである積分発火 LAF モデルのニューロン内の膜電位計算やスパイク信号の処理などに関して述べ、ホップフィールド型の ANN である BM の構成について述べ、既存のボルツマンマシンに SNN の要素を導入した DyBM の説明をおこなった。また、それぞれのニューラルネットワークの特徴や違いについても述べた、更に、スパイクコーディングの方法について例を挙げながら述べ、本研究で用いたコーディング方法につい


2.6 結言

でも述べた。次章では、本研究で提案した LAF モデルのニューロンとボルツマンマシンを組み合わせたニューラルネットワークである、SSA-BM の構成法について述べる。


- Single spike coding



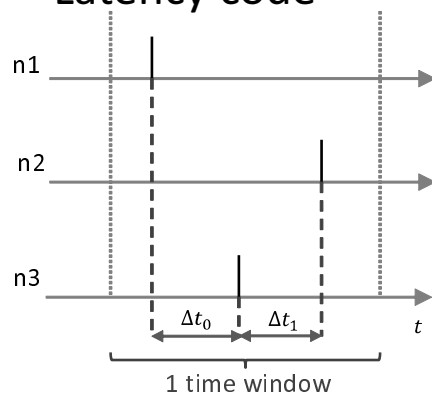
- Rank-order coding



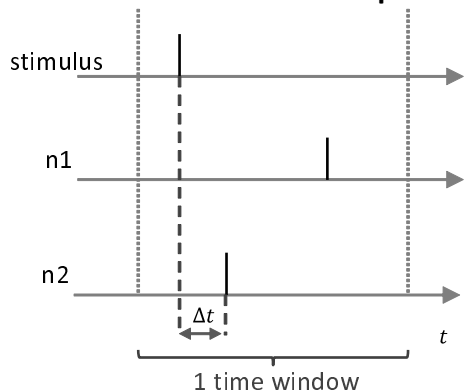
- Firing rate coding



- Latency code



- Time to first spike



- Phase coding




図 2.6 従来のスパイクコーディングの例

2.6 結言

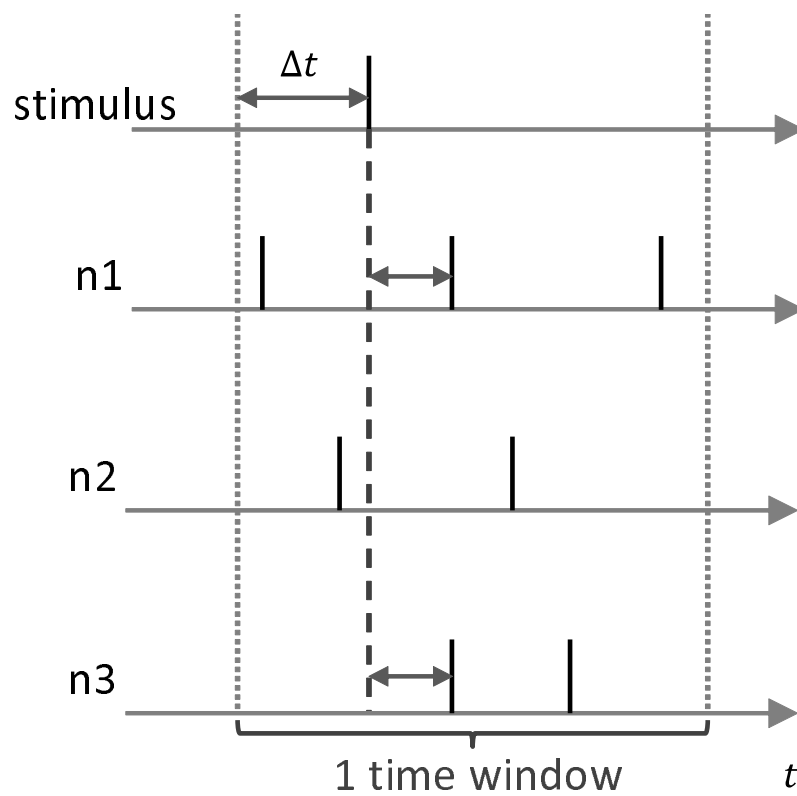


図 2.7 SSA-BM で用いるスパイクコーディング方法

第 3 章

SSA-BM(Single Spike Axon Boltzmann Machine)

3.1 緒言

本章では，提案する SSA-BM(Single Spike Axon Boltzmann Machine) の構成方法について述べる．SSA-BM は再帰構造を持つホップフィールド型のニューラルネットワークであるボルツマンマシン (Boltzmann Machine) に BNN(Biological Neural Network) のシミュレーションモデルである LAF(Leaky Integrate and Fire) モデルのニューロンを導入し，単一スパイクのみを許す軸索機能，および，最速反応型出力デコーダを新たに加えたモデルである．SSA-BM のネットワークの構成の他，スパイク信号のコーディング方法，情報伝播方法，出力を生成するためのデコード方法などについても述べる．また，SSA-BM を構成する上で参考にした DyBM に用いられており，SSA-BM にも導入している技術要素についても本章で述べる．

3.2 SSA-BM(Single Spike Axon Boltzmann Machine) の構成

前章にて，LAF モデルのニューロンと ANN のニューロンで行われる処理の違いを述べ，ボルツマンマシンの特徴について述べた．従来のボルツマンマシンは真と偽 (1 と 0) の確率 P をエネルギーの差 ΔE から求めて出力を決めるという確率に基いて動作するニュー

3.2 SSA-BM(Single Spike Axon Boltzmann Machine) の構成

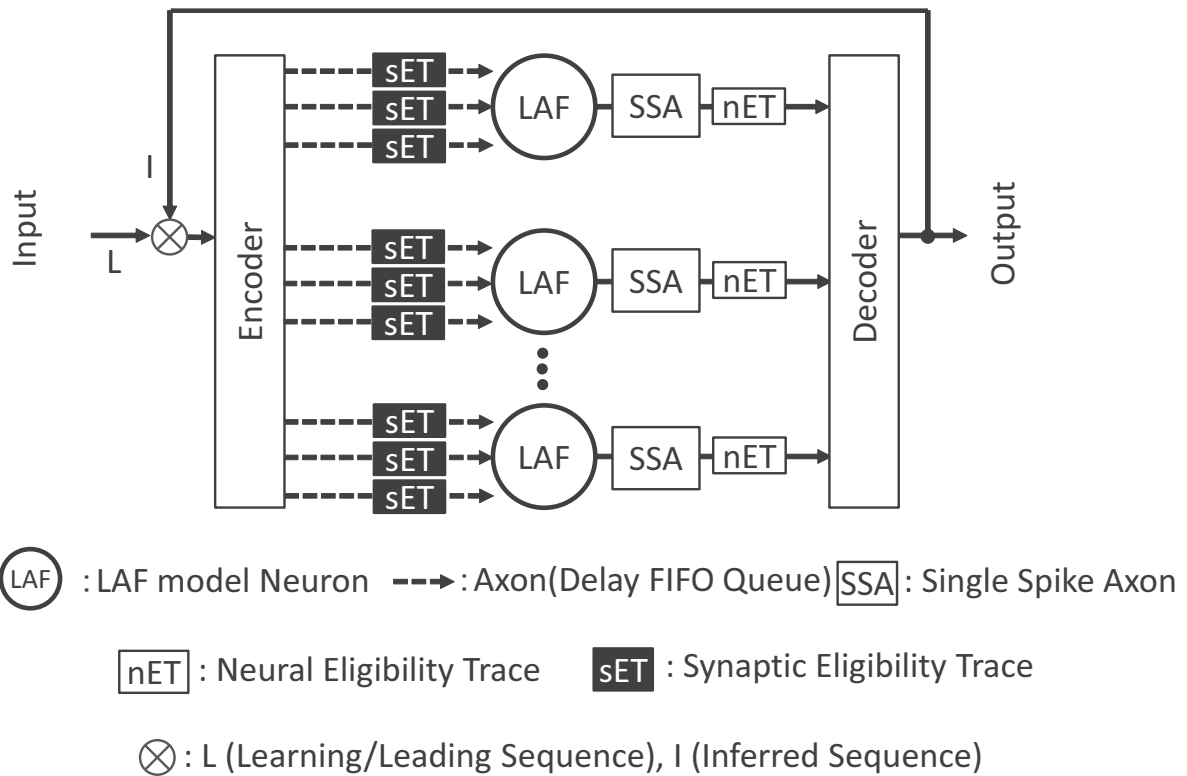


図 3.1 SSA-BM(Single Spike Axon Boltzmann Machine) の構成

ラルネットワークである。この処理は、BNN のニューロンのシミュレーションモデルと比較すると、実際の生物の神経細胞の動作の再現度が低い。また、ボルツマンマシンに SNN の要素をもたせた DyBM には、スパイク信号の到着時刻情報が省略されているため、任意のタイミングで入力信号が与えられる時系列パターンの処理ができず、対応させるために時間窓の概念で拡張した場合、与えられる時系列パターンが数倍になり学習が困難になってしまうという欠点を持つ。そこで、本研究では再帰構造を持つホップフィールド型のニューラルネットワークであるボルツマンマシン (Boltzmann Machine) に BNN(Biological Neural Network) のシミュレーションモデルである LAF(Leaky Integrate and Fire) モデルのニューロンを導入し、単一スパイクのみを許す軸索機能、および、最速反応型出力デコーダを新たに加えた、ニューラルネットワークである SSA-BM を提案する。提案する SSA-BM の全体図は図 3.1 に示す。

図 3.1 のように、SSA-BM はある時刻に受け取った動画のフレームの各ピクセル (2 値)

3.2 SSA-BM(Single Spike Axon Boltzmann Machine) の構成

を各ニューロンの入力データとして受け取り、次の時刻に受け取るであろう動画内フレームを出力する。外部から時系列パターンを与えられている間はこの動作を続けるが、外部からの時系列パターンが与えられなくなった場合は、ある時刻の出力フレームを次の時刻の入力フレームとすることで、与えられなくなった後の時系列パターンも自動で生成する。また、SSA-BM に外部から時系列パターンを与えられている間に、学習した時系列パターンと比べて時間的誤差を持つパターン (学習したフレームとフレームの間に位置するフレーム) が与えられた場合や、フレームの抜け落ちが発生していた場合などであっても、外部からの時系列パターンが与えられなくなった後に学習時と等しいフレームを生成し続けることが可能であり、ロバスト性を持つ。

SSA-BM は学習時に与えられる学習する時系列パターンの間隔よりも高い時間精度で離散事象シミュレーションを行う。学習時に与えられる時系列パターンが時間間隔 ΔT で与えられると仮定すると、 ΔT を 1 つの時間窓として扱う。離散事象シミュレーションは時間窓 ΔT よりも小さい Δt の間隔で行う。 ΔT に対して Δt が小さいほどシミュレーション精度が高いことを表す。学習時の時系列パターンの扱いは、入力データが真 (1) であった場合、時間窓内の最初のシミュレーション間隔で外部からスパイク信号を受け取り、入力データが偽 (0) であった場合、時間窓内にスパイク信号がないものとする。

以下に、スパイク信号のコーディング・デコーディング方法や軸索 (ニューロン間の結合) など、SSA-BM を構成するにあたって採用した要素や工夫点などについて述べる。

3.2.1 ニューロンの動作

提案する SSA-BM のニューロンの動作に関して述べる。

BNN のシミュレーションモデルである積分発火 LAF モデルのニューロンを用いているため、ニューロンの膜電位 V_m を第 2 章の式 2.1 を用いて計算する。膜電位 V_m が閾値を超えるとニューロンが発火し、膜電位 V_m は安静時膜電位へ下降する。第 2 章で説明した LAF のモデルのニューロンと異なるのは外部からの入力電流 I_{syn} である。SSA-BM ではあるシナプス後ニューロン j が N 個のシナプス前ニューロンから受ける時刻 t の入力電流 I_{syn} を

3.2 SSA-BM(Single Spike Axon Boltzmann Machine) の構成

式 3.1 を用いて求めている。

$$I_{syn}(t) = -b_j x_j^t - \sum_{i=1}^N \sum_{k=1}^K u_{i,j,k} \alpha_{i,j,k}^{t-1} x_j^t + \sum_{i=1}^N \sum_{l=1}^L v_{i,j,l} \beta_{i,j,l}^{t-1} x_j^t + \sum_{i=1}^N \sum_{l=1}^L v_{j,i,l} \gamma_{i,j,l}^{t-1} x_j^t \quad (3.1)$$

ここで、 b はバイアスを表し、 x は外部からの入力データを表す。 u 、 v はそれぞれ長期増強 LTP(Long Term Potentiation) 重みと長期抑圧 LTD(Long Term Depression) を表す。各重み u 、 v はスパイクタイミング依存可塑性 STDP(Spike Timing Dependent Plasticity) のメカニズムを元に更新される。LTP はニューロン間の結合を増強方向に、LTD は抑圧方向に学習するのに用いる。 α はシナプティックエリジビリティトレースを表し、 β は遅延 FIFO キュー内に格納されたスパイク信号から導いた発火の抑制量を表し、 γ はニューラルエリジビリティトレースを表す。 K 、 L はそれぞれ、一対のニューロン間にある結合の数を表す。

シナプティックエリジビリティトレース α とニューラルエリジビリティトレース γ は図 3.2 のように表すことができる。あるシナプス前ニューロン i とシナプス後ニューロン j 間のスパイク信号伝播におけるシナプティックエリジビリティトレース $\alpha_{i,j}$ は、ニューロン j がニューロン i の発火から遅延 d_{ij} 後に到着したスパイク信号から受けた影響量の和を記録している。また、ニューラルエリジビリティトレース γ はシナプス後ニューロン j が発火したことによるシナプス前ニューロン i の影響量の和を記録している。各エリジビリティトレース α と γ は式 3.2 と式 3.3 によって求める。

$$\alpha_{i,j,k}^{t-1} = \sum_{s=-\infty}^{t-d_{i,j}} \alpha_k(s) x_i[s] \quad (3.2)$$

$$\gamma_{j,l}^{t-1} = \sum_{s=-\infty}^{t-1} \alpha_l(s) x_j[s] \quad (3.3)$$

ここで、 α 関数は式 3.2 から求められる、スパイク信号がニューロンへ与える影響量である。式 3.2 と式 3.3 の k 、 l によって α 関数がピーク値 (1.0) に到達するまでの時間 τ_{α_s} が異なる。

3.2 SSA-BM(Single Spike Axon Boltzmann Machine) の構成

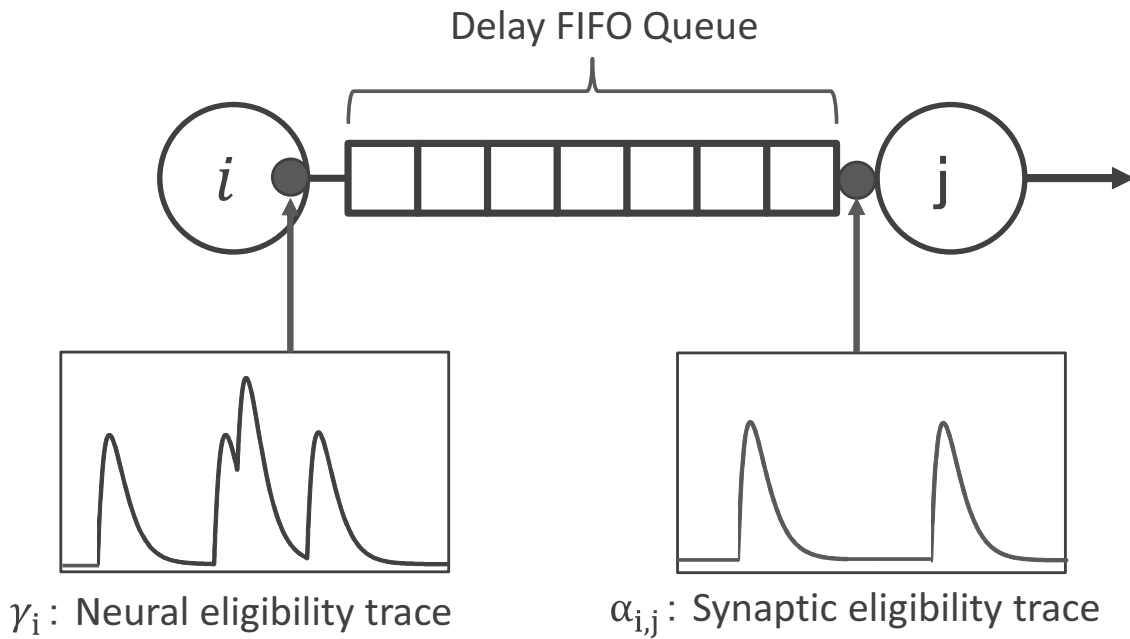


図 3.2 Neural eligibility trace と Synaptic eligibility trace

β は遅延 FIFO キュー内のスパイク信号から導かれる発火を抑制する値であり，式 3.4 によって求められる。

$$\beta_{i,j,l}^{t-1} = \sum_{s=t-d_{i,j}+1}^{t-1} \alpha_{i,j}(s-t)x_j[s] \quad (3.4)$$

これらの LTP, LTD 要素より，各ニューロンの発火タイミングとスパイク信号到着タイミングを考慮したニューロンへの影響を求める。

3.2.2 スパイク信号のコーディング・デコーディング

提案する SSA-BM のスパイク信号のコーディング・デコーディング方法に関して述べる。SSA-BM におけるスパイク信号のコーディング・デコーディングの流れは図 3.3 のようになる。外部から与えられた入力データは Encoder 部で単一のスパイク信号に変換され，各 LAF モデルニューロンへの軸索へ伝播される。各ニューロンはそれぞれ発火しスパイク信号を SSA(Single Spike Axon) 部へ伝播する。SSA 部で時間窓内で単一のスパイク信号に変換され Decoder 部へ伝播される。Decoder 部は伝播されたスパイク群を元に外部への出

3.2 SSA-BM(Single Spike Axon Boltzmann Machine) の構成

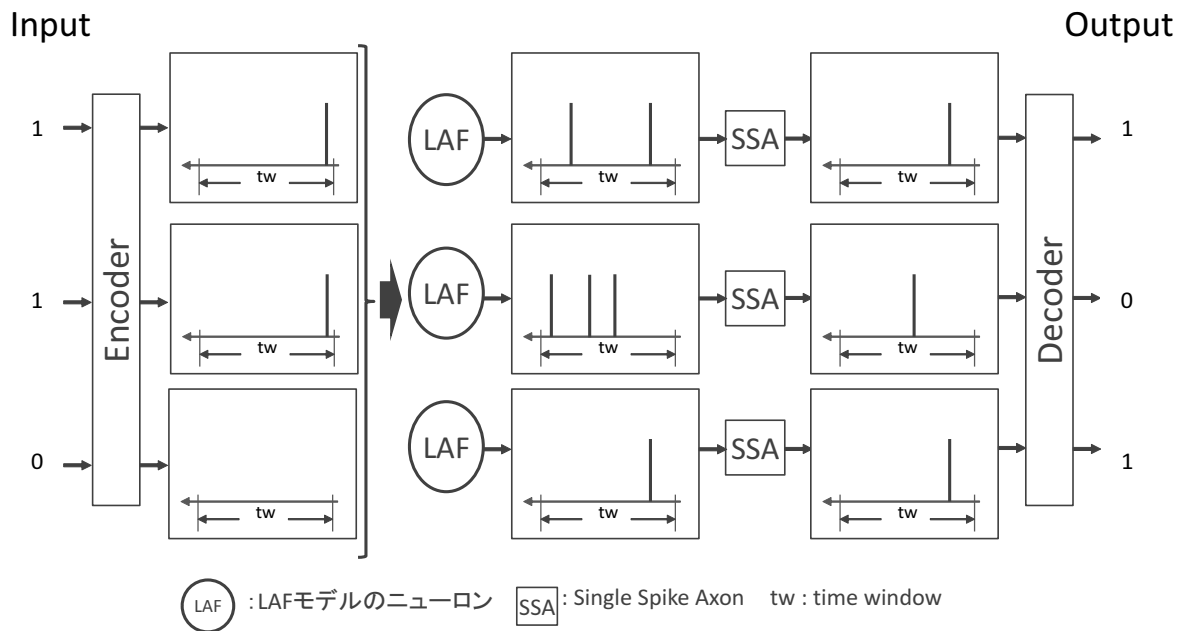


図 3.3 SSA-BM の情報の流れ方の例

力を生成する。以下，学習時，テスト時の Encoder 部，SSA 部，Decoder 部の伝播情報変換の仕組みをそれぞれ述べる。

まず，SSA-BM の外部からの入力時系列パターンのスパイク信号へのエンコーディングは図 3.3 の Encoder 部によって行われる。学習時に外部から入力されるデータのスパイク信号へのコーディング方法は図 3.4 のようになる。学習時は，入力データが 1 の場合，時間窓内の最初のシミュレーションタイミングでニューロンが発火し，スパイク信号が生成されたものとし，入力データが 0 の場合，時間窓内にスパイク信号が全くないものとする。

テスト時に外部から入力されるデータのスパイク信号へのコーディング方法は図 3.5 のようになる。図 3.5 は 1 つの time window 内に N 回のシミュレーションをするものとする。コーディング方法は基本的には学習時と同じであるが，テスト時は任意のタイミングでの入力を受け付けるため，学習時の時系列パターンと時間的に誤差のある入力データが与えられる場合がある。その場合は誤差の分遅れたシミュレーションタイミング Δt_n にスパイク信号が生成されるものとする。ただし，図 3.5 では，1 つの時間窓内に Δt_0 と Δt_n の複数のシミュレーションタイミングで入力を与えられているような図になっているが，これはそれ

3.2 SSA-BM(Single Spike Axon Boltzmann Machine) の構成




図 3.4 学習時の入力データのエンコード例

ぞれ別の時刻での入力の例であり，SSA-BM は，外部からの入力データは 1 つの時間窓内に 1 つ以下のシミュレーションタイミングでのみ与えられることを想定して動作している．

次に，SSA-BM のネットワーク内のスパイク信号の変換は図 3.3 の SSA 部で行われる．各ニューロンはある時間窓内で複数回発火することが可能であるが，伝播するスパイク信号は時間窓内で 1 つ以下である．伝播するスパイク信号は，あるニューロンにおいて外部からの入力データを受け取ったシミュレーションタイミングから最速で発火したスパイク信号としている．つまり，SSA 部は学習時は図 3.6 のように伝播するスパイク信号を選択し，テスト時は図 3.7 のように伝播するスパイク信号を選択する．

出力結果を生成するためのスパイク信号のデコードは図 3.3 の decoder 部で行われる．外部からの入力データが入ってきた瞬間から時間窓内で最も早く発火したニューロン群の結果

3.2 SSA-BM(Single Spike Axon Boltzmann Machine) の構成

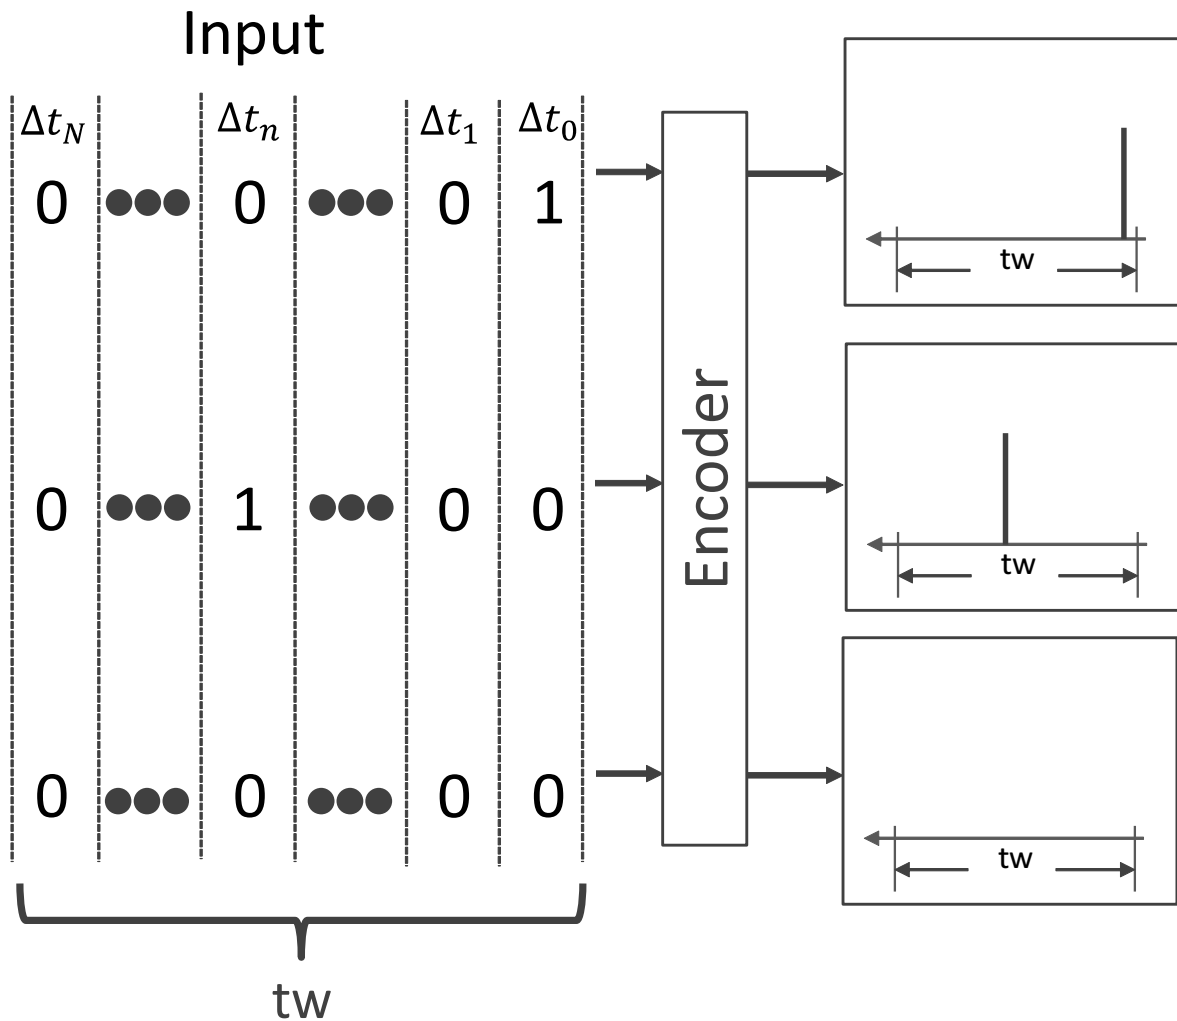


図 3.5 テスト時の入力データのエンコード例

を 1 とし，そのニューロン群よりも遅く発火した，もしくは発火しなかったニューロン群の結果を 0 として扱う．学習時は常に時間窓内の最も早いシミュレーションタイミングで外部からの入力データが与えられるため，図 3.8 のように出力結果を生成する．テスト時は時間窓内で任意のタイミングで外部からの入力が入ってくるため，図 3.9 のように出力結果を生成する．学習時は，デコードして生成した出力結果は外部に出力される．テスト時は，外部から入力データを与えられている間は学習時と同じように外部に出力するのみだが，外部から入力データが与えられなくなった場合は，出力結果を次の時刻 (次の時間窓) の入力データとしてネットワークに与える．

3.2 SSA-BM(Single Spike Axon Boltzmann Machine) の構成

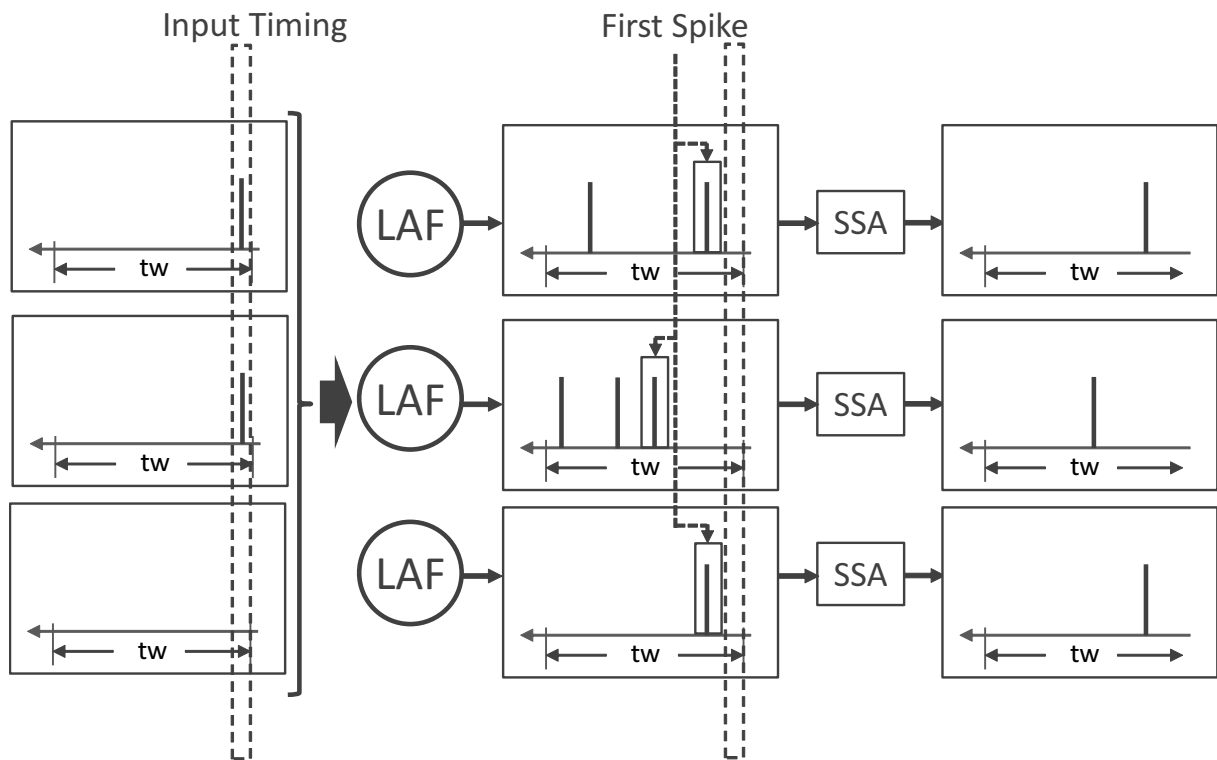


図 3.6 学習時の SSA 部のスパイク信号変換の例

3.2.3 軸索の構成

提案する SSA-BM の軸索は図 3.10 のような FIFO 構造の遅延キューで構成されており、シナプス前ニューロンの発火から遅延キュー分遅れてシナプス後ニューロンに到着する。遅延キューの長さはランダムで設定しており、同じシナプス前ニューロンのスパイク信号でもシナプス後ニューロンごとに到着するタイミングは異なる。また、一対のシナプス前ニューロンとシナプス後ニューロンの軸索は 1 つではなく、複数設定しており、Spike Prop の構造を取る。各軸索は遅延キューの長さは等しいが、重みはそれぞれ異なり、また、スパイク信号をニューロンの膜電位に与える影響量へ変換する α 関数も異なる。スパイク信号を受け取り、 α 関数によって影響量へと変換した結果はエリジビリティトレースとして記憶される。エリジビリティトレースにはニューラルエリジビリティトレースとシナプティックエリジビリティトレースがあり、それぞれが発火及びスパイク信号の到着から受ける影響量の記憶をしている。

3.2 SSA-BM(Single Spike Axon Boltzmann Machine) の構成

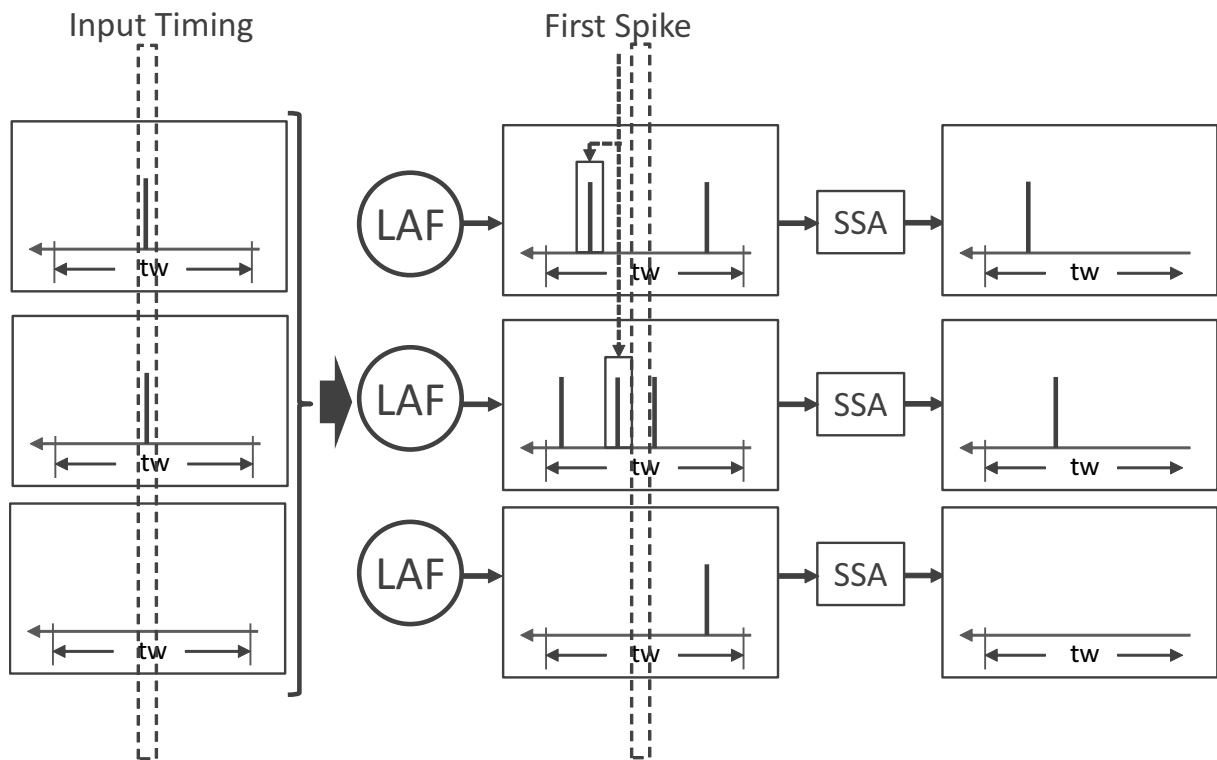


図 3.7 テスト時の SSA 部のスパイク信号変換の例

以下は、それぞれ軸索を構成している要素について詳しく説明する。

遅延 FIFO キュー

提案する SSA-BM の軸索は図 3.10 のように、FIFO 構造の遅延キューで構成されている。シナプス前ニューロン i からシナプス後ニューロン j へスパイク信号が伝播し、その伝播遅延が d_{ij} であるとする、遅延 FIFO キューの長さは $d_{ij} - 1$ となる。この遅延 FIFO キューの長さ $d_{ij} - 1$ はネットワーク初期化時にランダムで 0 以上の長さで設定される。この遅延 FIFO キューを設定することで、ニューロン間の距離の違いを表現できる。また、今後そのシナプス後ニューロンへのタイミングでスパイク信号が入ってくるかという情報をニューロンの膜電位 V_m の計算や学習へ利用できる。

3.3 結言

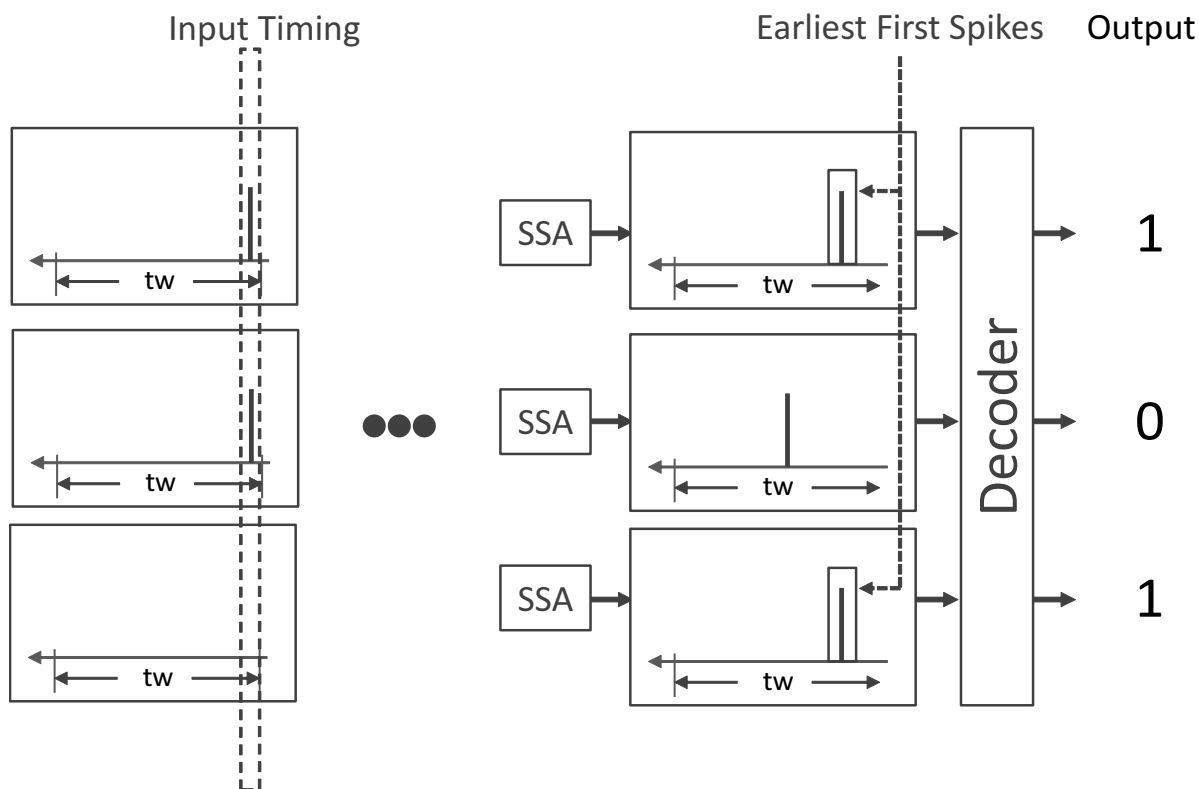


図 3.8 学習時のスパイク信号のデコード例

Spike Prop 構造

SSA-BM の軸索は図 3.10 のように，一対のシナプス前ニューロンとシナプス後ニューロン間に複数の結合を持つ．同ニューロン間の結合の遅延 FIFO キューの長さは等しいが，重みと alpha 関数の τ_{α} が異なる．これにより，各結合ごとにスパイク信号がシナプス後ニューロンへ与える影響量とその時間帯が異なるため，結合の細かな調整が可能となる．

3.3 結言

本章では，提案する SSA-BM(Single Spike Axon Boltzmann Machine) の構成方法について述べた．SSA-BM は再帰構造を持つホップフィールド型のニューラルネットワークであるボルツマンマシン (Boltzmann Machine) に BNN(Biological Neural Network) のシミュレーションモデルである LAF(Leaky Integrate and Fire) モデルのニューロンを導入し，単

3.3 結言

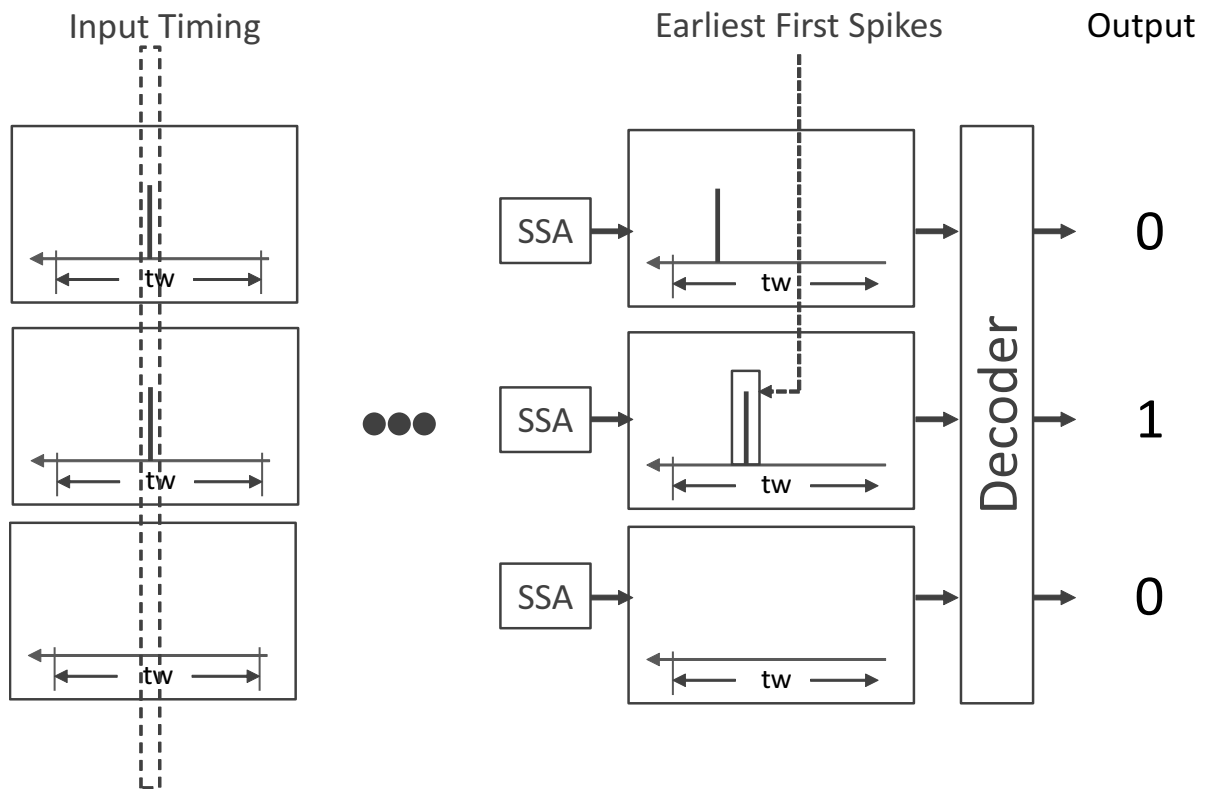


図 3.9 テスト時のスパイク信号のデコード例

一スパイクのみを許す軸索機能，および，最速反応型出力デコーダを新たに加えたモデルである．SSA-BM のネットワークの構成の他，スパイク信号のコーディング方法，情報伝播方法，出力を生成するためのデコード方法などについても述べた．また，SSA-BM を構成する上で参考にした DyBM に用いられており，SSA-BM にも導入している技術要素についても本章で述べた．

3.3 結言

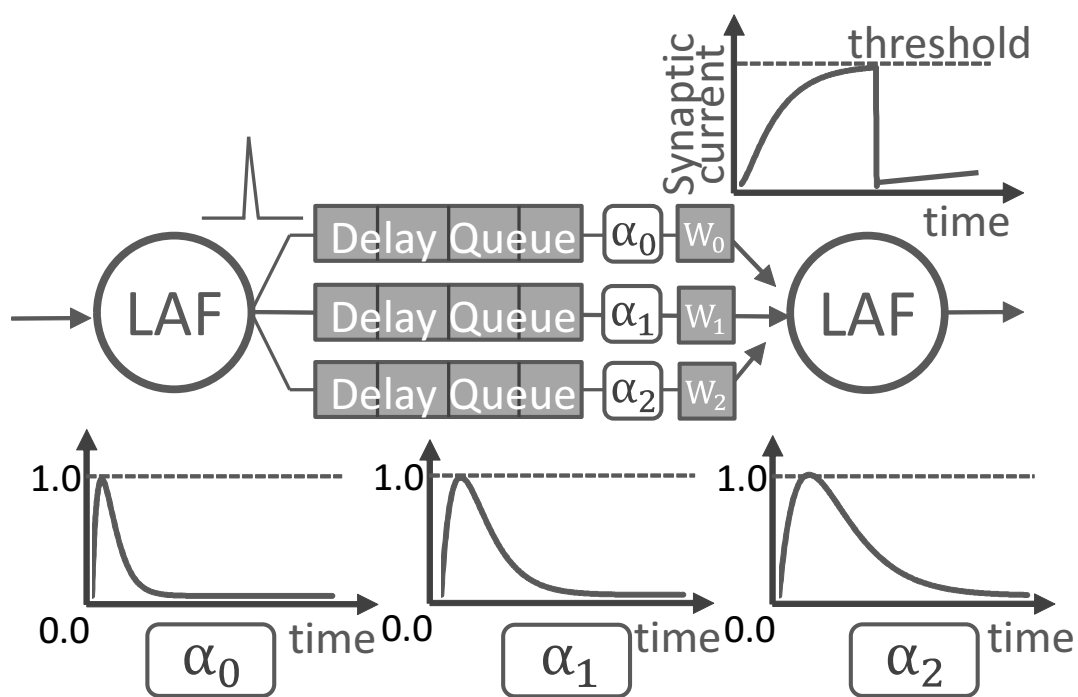


図 3.10 SSA-BM のニューロン間の結合

第 4 章

評価

4.1 緒言

本章では，提案する SSA-BM(Single Spike Axon Boltzmann Machine) の評価を行う．評価は，動画内の物体軌道予測課題に対して行う．評価には，規則的な軌道を取る物体と不規則的な軌道を取る物体の動画パターンを用いた．それぞれ各パターンの動画に対して，学習時に用いる動画とテスト時に用いる動画が等しい，正常なフレームの動画に対する予測能力と必要な学習回数を評価する．更に，学習時に用いた動画と比較して時間的誤差フレームや欠落フレームが存在する，例外フレームを持つ動画を用いた場合に関してロバスト性を評価する．その後，結果を元に考察を行う．

4.2 性能評価

提案する SSA-BM の性能評価を行う．まず評価条件について述べ，評価結果を示し，その結果から考察を行う．

4.2.1 評価条件

SSA-BM の性能評価のために，本研究では動画内の物体軌道予測課題を用いた．動画はフレームサイズを $4(\text{pixel}) * 4(\text{pixel})$ とし，フレーム数は 4, 8, 16 フレームとした．また，動画内を移動する物体は $2(\text{pixel}) * 2(\text{pixel})$ の正方形とし，常に一定の速度 (1 フレームあたり 2pixel) で移動するものとした．学習に用いる動画として，規則的な軌道を取る物体と不

4.2 性能評価

規則的な軌道を取る物体の動画パターンをそれぞれ 10 パターン用いた。ここで、規則的な軌道を取る物体の動画パターンとは以下の条件を満たすものとする。以下の条件を満たさない場合を、不規則的な軌道を取る物体の動画パターンとする。

- 図 4.1 の (a), (b), (c) の軌道を取るもの
- 図 4.1 の (a), (b), (c) の軌道を線対称, 点対称にした軌道を取るもの
- 上記の軌道を繰り返す軌道を取るもの
- 上記の軌道とそれを逆順にした軌道を繰り返す軌道を取るもの

この条件から生成した規則的な軌道を取る物体の動画パターンと不規則的な軌道を取る物体の動画パターンの例はそれぞれ図 4.2, 図 4.3 のようになる。

学習は、与えられたフレームに対して、次時刻のフレームを出力にするように行う。学習時は動画の全フレームが外部からの入力として与えられる。テスト時はフレームを前半と後半に分け、前半のみを外部からの入力として与える。前半のフレームを受け取った後は、SSA-BM の出力を次時刻の入力フレームとして与えることで後半フレームを自動的に全て




図 4.1 規則的な物体軌道の条件

4.2 性能評価

出力させる。これを学習時に用いたフレームと比較して等しいか否かを評価し、等しい場合予測能力を持つとする。外部から与える入力である前半フレームが学習時と等しい場合を正常な入力時系列パターンとし、学習時のフレームと比較して時間的誤差や欠落を持つフレームを含む場合を例外を含む入力時系列パターンとする。

規則的な軌道を取る物体の動画パターンと不規則的な軌道を取る物体の動画パターンのそれぞれについて、正常な入力時系列パターンに対する予測率と必要な学習回数、例外を含む入力時系列パターンに対するロバスト性について評価する。

また、SSA-BM に導入している LAF モデルのニューロンのパラメタを表 4.1 に示す。時間窓間隔 ΔT が $10.0[ms]$ 、シミュレーション精度 Δt が $1.0[ms]$ であるため、1つの時間窓内で10回のシミュレーションを行うこととなる。

表 4.1 LAF モデルのパラメタ

安静時膜電位 V_{reset}	$-70.0mV$	不応期 τ_{ref}	$1.0ms$
閾値電圧 V_{th}	$-55.0mV$	膜時定数 τ_m	$20.0ms$
膜容量 C_m	$250.0pF$	シミュレーション精度 Δt	$1.0ms$
膜電流 I_e	$376.0pA$	時間窓 ΔT	$10.0s$

4.2.2 正常な入力時系列パターンに対する予測率と必要な学習回数

テスト時に外部から与える入力である前半フレームが学習時と等しい場合、つまり正常な入力時系列パターンが与えられる場合の予測能力と必要な学習回数を評価する。評価は、規則的な軌道を取る物体の動画パターンと不規則的な軌道を取る物体の動画パターンそれぞれについて行う。入力フレームの例を図 4.4 に示す。学習時に図 4.4 の 1 を与えたとして、テスト時にも 1 を与える。ただし、テスト時は点線で囲まれたフレームまでを外部から与え、それ以降はある時刻の SSA-BM の出力フレームを次時刻の入力フレームとし、動画の後半フレームを生成する。

この時の、動画のフレーム数が 4, 8, 16 フレームの場合について予測率と学習回数を表

4.2 性能評価

表 4.2 物体軌道予測率と学習回数 (正常な前半フレーム入力時)

		4	8	16
予測率 (%)	規則的な軌道	100	100	100
	不規則的な軌道	100	100	100
学習回数 (回)	規則的な軌道	100	200	700
	不規則的な軌道	200	500	15,000

4.2 に示す。表 4.2 に記した学習回数は学習が終了しているか否かの判定は学習 100 回につき 1 回行っているため、100 回単位での目安値となる。故に、入力として与えられる動画パターンや乱数を用いて生成した SSA-BM の初期パラメータによって多少前後する。

表 4.2 の結果から、SSA-BM は学習済みの時系列パターンに対しては、規則的な軌道と不規則的な軌道の両方のパターンで高い精度での物体軌道予測が可能であることがわかった。また、必要な学習回数に関しては、不規則的な軌道を取るパターンの方が規則的な軌道を取るパターンに比べ、フレーム数に対する増加量が大きいことがわかった。

4.2.3 例外を含む入力時系列パターンが与えられた場合のロバスト性

テスト時に学習時のフレームと比較して時間的誤差や欠落を持つフレーム、つまり例外フレームが与えられる場合の SSA-BM のロバスト性を評価する。ロバスト性は学習時に用いた動画と比較して遅延フレームを持つ動画をテストに用いた場合、抜け落ちたフレームが存在する動画を用いた場合の 2 つの場合に関して評価する。

学習時に用いた動画と比較して遅延フレームを持つ動画をテストに用いた場合とは、学習時には図 4.4 の 1 を用い、テスト時には図 4.4 の 2.1 を用いたような場合を指す。

また、抜け落ちたフレームが存在する動画を用いた場合とは、学習時には図 4.4 の 1 を用い、テスト時には図 4.4 の 2.2 を用いたような場合を指す。

どちらの場合についても、動画は前半と後半フレームの合計が 16 フレームとし、外部からの入力として与えられる前半フレームに例外フレームを混ぜる。前半 8 フレーム中、何フ

4.2 性能評価

表 4.3 物体軌道予測率 (例外フレーム入力時)

例外フレーム		最大許容フレーム数
時間的誤差フレーム (5ms 遅延)	規則的な軌道	任意の 5 フレーム
	不規則的な軌道	任意の 0 フレーム
抜け落ちフレーム	規則的な軌道	任意の 4 フレーム
	不規則的な軌道	任意の 0 フレーム

フレームまでであれば後半フレームを正しく出力できたかという評価の表 4.3 に示す。

表 4.3 の結果から、SSA-BM は、規則的な軌道を取るパターンを学習した場合、遅延フレームを与えられたときは 5 フレームまで、抜け落ちフレームを与えられたときは 4 フレームまでであれば正しいフレームを出力することができ、ロバスト性を持つことがわかった。ただし、前半 8 フレーム中 7, 8 フレーム目に例外フレームを与えた場合は、例外フレーム数に限らず正しいフレームを出力できなかった。また、不規則的な軌道を取るパターンを学習した場合は、時間的誤差フレームを与えられたとき、抜け落ちフレームを与えられたとき共に正しいフレームを出力することが出来ず、ロバスト性を持たないことがわかった。

SSA-BM が規則的な軌道を取る動画パターンに対して例外フレームへのロバスト性を持つ反面、不規則的な軌道を取る動画パターンに対してロバスト性を持たない理由として、動画内に等しい連続フレームパターンが複数存在する可能性が高いことが挙げられる。等しい連続フレームパターンを与えられた場合、それ以前の入力フレームにより SSA-BM のネットワーク内の状態が多少異なるとは言え、近くなってしまうことが考えられる。その微小な差異を正常な入力であれば区別が可能であるが、例外フレームが入ってきてしまうとネットワークの状態が大きく乱れ、その後の出力にも影響を及ぼし、正しい出力を得ることが出来ないのではないかと考える。

4.3 結言

4.3 結言

本章では，提案する SSA-BM(Single Spike Axon Boltzmann Machine) の評価を行った．評価は，動画内の物体軌道予測課題に対して行った．評価には，規則的な軌道を取る物体と不規則的な軌道を取る物体の動画パターンを用いた．それぞれ各パターンの動画に対して，学習時に用いる動画とテスト時に用いる動画が等しい，正常なフレームの動画に対する予測能力と必要な学習回数を評価した．更に，学習時に用いた動画と比較して時間的誤差フレームや欠落フレームが存在する，例外フレームを持つ動画を用いた場合に関してロバスト性を評価した．その後，結果を元に考察を行った．

4.3 結言

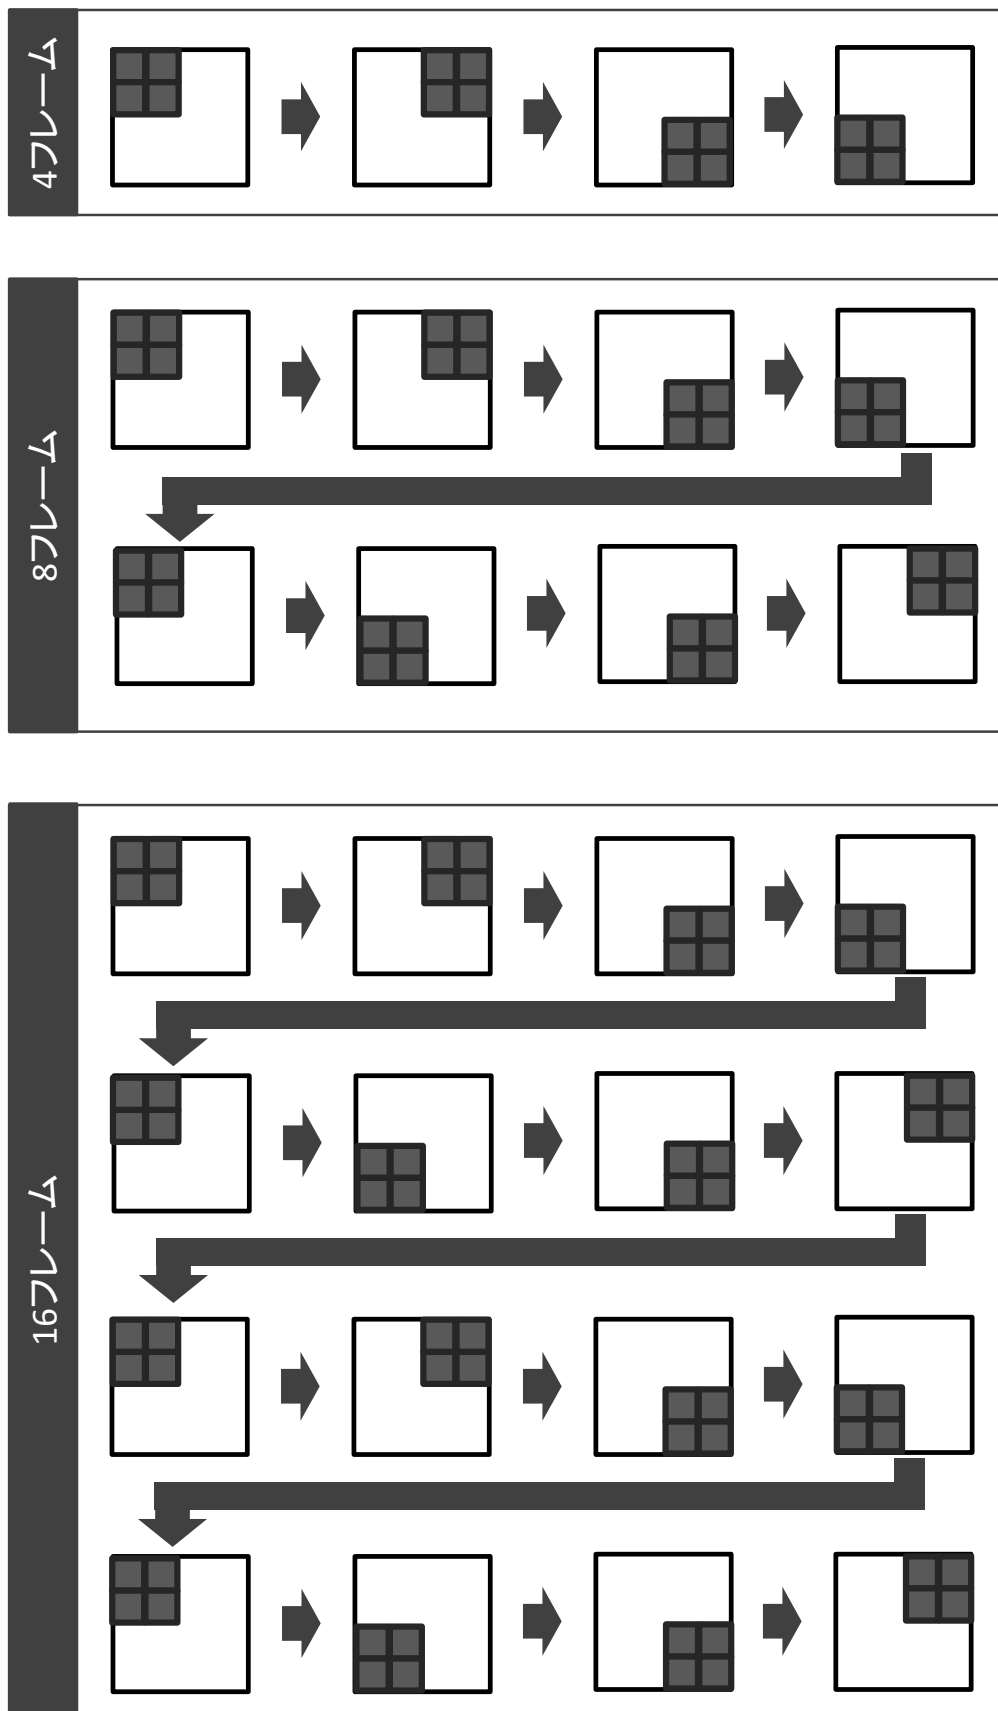


図 4.2 規則的な物体軌道の例

4.3 結言




図 4.3 不規則的な物体軌道の例

4.3 結言

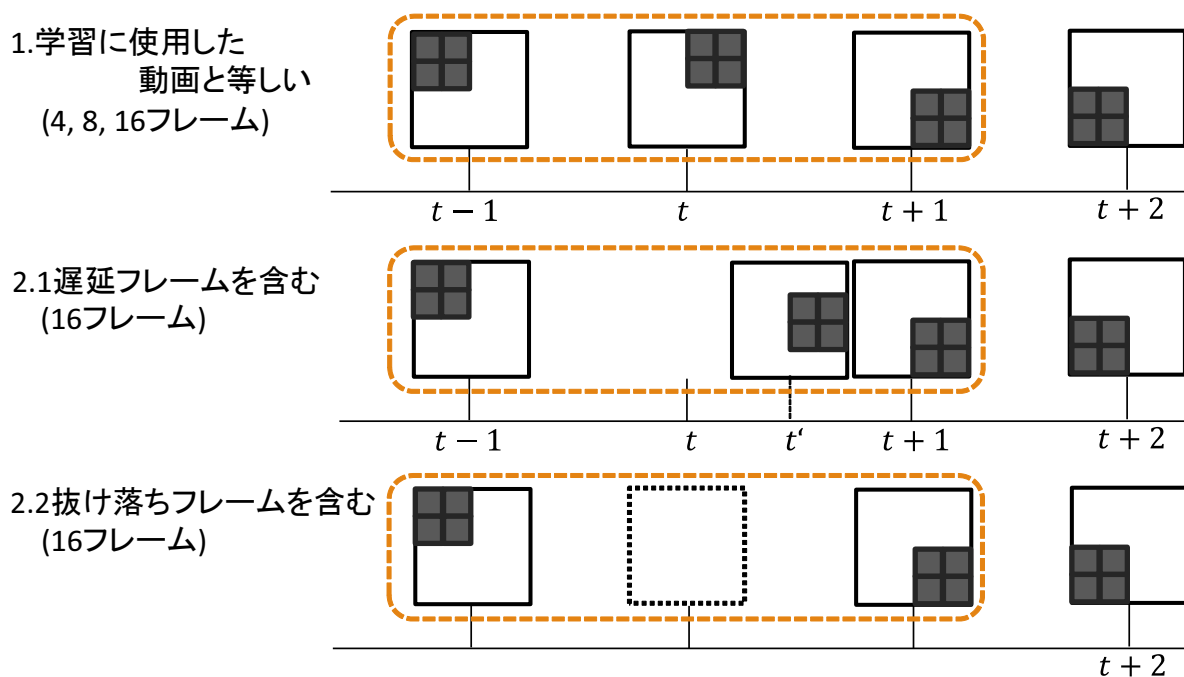


図 4.4 学習時とテスト時の入力パターン例

第 5 章

結論

本研究では, SSA-BM(Single Spike Axon Boltzmann Machine) を提案した. 提案モデルは, STDP 型学習が可能な積分発火 LAF(Leaky Integrate and Fire) モデルニューロンからなるボルツマンマシン (Boltzmann Machine) に対して, 単一スパイクのみを許す軸索機能, および, 最速反応型出力デコーダを新たに加えたモデルである. 本論文では SSA-BM を構成する上で用いた要素技術や, 構成方法, 評価などについて述べた. LAF モデルニューロンは BNN(Biological Neural Network) のシミュレーションモデルの 1 つであり, ボルツマンマシンは ANN (Artificial Neural Network) として研究されるホップフィールド型のニューラルネットワークである.

BNN のシミュレーションモデルに関する研究 [2] は, 動物の脳を忠実に計算機上で再現することを目的としている. BNN のシミュレーションモデルとしては代表的な例として, 発火率 (Firing Rate) モデル, Hodgkin-Huxley モデル, マルチコンパートメントモデルなどがある. 本研究で採用した LAF モデルは, 膜電位の変化やスパイク信号の到着タイミングの差異等を再現していることが主な特徴である. BNN のシミュレーションモデルはそれぞれ精度は違うが, ニューロンの動作を数理的に表現している. BNN のシミュレーションモデルニューロンのシミュレーションには膨大な演算量を必要とし, 従来, 汎用型コンピュータでは実用的な時間でシミュレーション結果を得るのが難しかった. だが, 近年では, 計算機の性能が向上したことで, スーパーコンピュータではより大規模で正確なニューロンのシミュレーションを行うことが可能となり, スーパーコンピュータ等を使用せずともシミュレーションモデルの種類や規模を選ぶことでコモデティコンピュータでもシミュレーションが可能となってきている.

ANNに関する研究は、ニューラルネットワークを活用して実用的に役に立つ技術を開発することを目的している。ANNは一般的にヘブ則と呼ばれる学習則によって実際のニューロンで言うところのシナプス強度となる重みを変化させ、問題解決能力を持たせる。ANNには大きく分けてパーセプトロン型とホップフィールド型のネットワーク形態が存在する。パーセプトロン型は、基本的に情報が一方向に伝搬されるネットワーク形態である。一方、ホップフィールド型は、情報が相互に伝搬されるネットワーク形態である。

ネットワークの代表的な例としては、パーセプトロン型のニューラルネットワークはFNN(Feedforward Neural Network)やAE(AutoEncoder), RNN(Recurrent Neural Network)等が挙げられ、ホップフィールド型のニューラルネットワークの例としてはボルツマンマシン(Boltzmann Machine)が挙げられる[4]。近年では、これらのホップフィールド型のニューラルネットワークを応用した、3層より多層なニューラルネットワークであるDNN(Deep Neural Network)が注目を集めている。加えて、本研究で採用したボルツマンマシンのような、与えられた入力データに対して、それまでの入力データによって変化させたニューロンやネットワークの状態を踏まえた出力データを返すようなニューラルネットワークも注目を集めている。これらは、前入力データに対する処理結果を再び入力として取ることで、入力を受け取る以前までの情報を踏まえた処理結果を出すことができ、言語翻訳などに応用されている。例として挙げたニューラルネットワークはどれも基本的にはBNNのようにニューロン間の信号伝達をスパイク信号で行っているわけではなく、発火率にあたる数値で信号伝達を行っている。すなわち、ニューロン内の膜電位の変化などは計算しておらず、BNNと比較すると神経細胞の計算処理の大部分を抽象化し省いていると言える。

これらの2つのニューラルネットワークに関する研究は今まで交わることが少なく、それぞれ独立して研究が進められてきた。と言うのも、先に述べたようにBNNは脳の忠実な再現を目的としており、神経細胞生物学の分野として研究が進められてきたが、ANNは技術開発を目的としており、ITの分野として研究が進められてきたからである。しかしながら、近年では、計算機の性能が向上したことでBNNのニューロンモデルのシミュレーションが比較的容易になったこと、ANNの研究が進みこれまで解くことができなかった難解な課題

を解くことができる DNN や時系列によって変化する課題を解くことができるニューラルネットワークが登場したことから、BNN のシミュレーションモデルと ANN を組み合わせたニューラルネットワークの研究が盛んになってきている。

BNN のシミュレーションモデル，もしくはそれを簡略化したモデルを用いたニューラルネットワークはスパイク信号を用いて情報の伝播を行うため，SNN(Spiking Neural Network) と呼ばれる。SNN の例として，IBM 社が発表した DyBM(Dynamic Boltzmann Machine) が挙げられる。これは，BNN のシミュレーションモデルを簡略化したものとボルツマンマシンを組み合わせた SNN であり，時系列パターンを記憶することが可能である。DyBM は過去の入力データを踏まえた出力を返すことが可能なボルツマンマシンと，スパイク信号を用いた学習則である STDP(Spike Timing Dependent Plasticity) を組み合わせることで，時系列パターンの記憶を可能にし，学習した時系列パターンの前半数パターンを入力として与えれば残りは入力を与えずとも時系列パターンを出力することができる。しかし，この DyBM はニューロンの動作を離散的にシミュレーションしており，シミュレーションタイミングにおけるスパイク信号の扱いは受け取ったか否か，もしくは発火したか否かの 0-1 の処理である。そのため，外部からの入力信号が学習時の時系列パターンに対して多少前後するような，任意のタイミングで入力信号が与えられる時系列パターンに対応できない。また，任意のタイミングで入力信号が与えられる時系列パターンに対応するために学習時の時系列パターンを時間窓の概念で拡張した場合，入力時系列パターンが数倍になってしまい，学習が困難になってしまうという欠点を持つ。これにより，学習時の時系列パターンと比べて，離散シミュレーションのタイミングとタイミングの間にあるパターンが与えられる可能性のある場合や，与えられた時系列パターンに抜け落ちが発生する可能性がある場合課題に対して応用が難しい。近年，高フレームレート化が進む動画への応用や，動画のフレーム内のピクセルの変化量に応じてフレームレートが動的に変化する ATIS カメラなどへの応用を考えた場合，先に述べたような欠点は大きな問題となる。

そこで，DyBM を参考に，再帰構造を持つニューラルネットワークに BNN を導入し，高精度で離散事象シミュレーションすることで，時空間的パターンの学習及び予測が可能にな

り，時間的誤差や抜け落ちを持つ入力パターンに対してロバストな処理が可能になるのではないかと考えた。

本研究では，SSA-BM(Single Spike Axon Boltzmann Machine) を提案した．提案モデルは，STDP 型学習可能な LAF モデルニューロンからなる完全結合 RNN に対して，単一スパイクのみを許す軸索機能，および，最速反応型出力デコーダを新たに加えたモデルである．本論文では SSA-BM を構成する上で用いた要素技術や，構成方法，評価などについて述べた．

第 2 章では，提案モデルである SSA-BM に用いている BNN シミュレーションモデルである LAF モデルのニューロン，ボルツマンマシン，SSA-BM を構成する上で参考にした DyBM，スパイクコーディング方法についての説明をした．LAF モデルのニューロンに関しては，発火率を元に情報を扱う ANN との違いや，ニューロンの膜電位などを用いた発火の仕組み，スパイク信号による情報伝播などについて述べた．ボルツマンマシンに関しては，ネットワーク内の各ニューロンが相互に結合したホップフィールド型のニューラルネットワークの構造や特徴，階層構造を持つパーセプトロン型のニューラルネットワークと比較したときの利点などについて述べた．DyBM に関しては，SNN としての要素を持つボルツマンマシンであり，時系列パターンを記憶することが可能であるという特徴と，スパイク信号到着時刻を省略しているため任意のタイミングでの入力にそのままでは対応できないという欠点を持つこと，そしてその構造について述べた．スパイクコーディング方法に関しては，まず従来のスパイクコーディング方法を幾つか例として挙げ，特徴などを述べた．その後，本研究で提案した SSA-BM を構成する上で満たすべき条件を挙げ，その条件を満たすために新しく今回用いたスパイクコーディング方法を説明した．

第 3 章では，提案モデルである SSA-BM の構成方法について述べた．まず，ネットワーク全体の構成について述べた後，ニューロンの動作やスパイク信号のコーディング・デコーディング方法，軸索の構成について述べた．ニューロンの動作に関しては，第 2 章に述べた LAF モデルのニューロンを元に，ニューラルエリジビリティトレースとシナプティックエリジビリティトレースの扱い方や，そこからニューロンの膜電位を求める方法などについて述

べた。スパイク信号のコーディング・デコーディング方法に関しては、ネットワーク全体の情報伝播の流れについて述べた後、Encoder 部、SSA 部、Decoder 部での情報の変換方法について詳しく述べた。学習時とテスト時で情報の変換が異なる部分があるため、その差についても述べた。軸索の構成に関しては、遅延 FIFO キューや Spike Prop など、軸索を構成する上で用いている要素技術やそれらの要素を SSA-BM に導入する上での工夫について述べた。

第 4 章では、SSA-BM を評価する上でのパラメタや評価項目、評価結果を示し考察をした。評価は、動画内の物体軌道予測課題を用いて行った。動画は物体が規則的な軌道を取る場合と不規則的な軌道を取る場合を用意し、それぞれについて正常なフレームの動画を入力として与えた場合の予測率と必要な学習回数を評価した。また、学習時と比較して時間的誤差や欠落したフレームと言った例外フレームを持つ動画を入力として与えた場合のロバスト性についても評価した。動画はフレームサイズを $4(\text{pixel}) \times 4(\text{pixel})$ とし、フレーム数は正常なフレームの動画は 4, 8, 16 フレーム、例外フレームを持つ動画は 16 フレームとした。動画のパターンはそれぞれ 10 パターンずつ用意した。結果から、SSA-BM は学習済みの正常なフレームの動画に対して、物体が規則的な軌道を取る場合も不規則的な軌道を取る場合も高い予測率を持つことがわかった。また、時間的誤差や欠落したフレームを持つ動画に対して、物体が規則的な軌道を取る場合はロバスト性を持つことが示せたが、物体が不規則的な軌道を取る場合はロバスト性を持たないことがわかった。

今後の課題としては、複数の物体軌道パターンに対しての予測が可能になるように改良することや、より大きなフレームサイズ、フレーム数の動画に対して応用可能に改良することが挙げられる。また、規則的な軌道を取る物体だけでなく、不規則的な軌道を取る物体にも例外フレームに対してロバスト性を持つように改良する必要がある。

より大きなフレームサイズを扱えるように拡張することを考えた場合、2つの方法が考えられる。まず、単純にニューロン数を増やす場合である。これは、フレームサイズに合わせて提案した SSA-BM のニューロン数を増やす方法になるが、フレームサイズが大きくなるに連れて計算量が指数的に増えていき膨大になってしまうため、現実的な方法とはいえない

い。次に、空間的窓を用いて大きなフレームサイズに対応する場合である。これは、ニューロン数は本論文の評価で試したような $3*3$ や $4*4$ から増やさず、それを 1 つの空間的窓として扱い、フレームサイズに合わせて敷き詰めるという方法である。この方法であれば、SSA-BM のニューロン数ではなく SSA-BM 自体の数が増えるだけであるので計算量は比例的に増えていく。しかしながら、単純に敷き詰めるだけでは空間的窓間は独立した処理を行う行ってしまうため、隣接するネットワーク間に関連性を持たせる機能を追加する必要性が考えられる。

不規則的な軌道を取る物体に対するロバスト性を向上させる方法としては、対応できるフレームサイズを大きくすることが挙げられる。というのも、本論文で試した動画内の物体の写ったフレームパターンは学習時は 4 パターンのみであり、現時刻の入力、過去の入力、ネットワーク内の状態に大きな差が生まれにくい。逆に、非常に大きなフレームサイズに対応できたと仮定すると、物体が不規則的な軌道を取ったとしても同じ場所を同じ軌道で近い時間間隔で通ることは稀であろう。現実的な課題へ対応することを考えると、不規則的な軌道を取る物体に対するロバスト性を向上させるにはまず、上で述べたような方法でより大きなフレームサイズを扱うことができるように拡張するべきではないかと考える。

また、本研究では 2 値化された動画を対象に SSA-BM の設計・評価している。そのため、今後の拡張として、グレースケールのフレームへの対応を考える必要がある。この方法として、スパイク信号の到着タイミングをグレースケールの値にも対応させた扱いにする、という方法が挙げられる。高速に移動する物体の半透明の残像が写ったグレースケールのフレームが与えられた場合、物体本体と残像間には時間的誤差がある。故に、同タイミングで与えられた入力をスパイク信号にコーディングする際に、伝播するスパイク信号のタイミングをグレースケールの値に対応させることは可能であると考えられる。しかしその場合、残像が時系列的に過去のデータであるため、与えられる物体と背景色の関係を考えてスパイク信号コーディングを行う必要がある。グレースケールフレームへの対応が可能になれば、CNN[10][11]などで RGB を扱う際に用いられているような方法で RGB 表現のフレームへの対応も見えてくると考えられる。

謝辞

本研究を進めるにあたり、日頃より懇切丁寧なご指導、ご鞭撻を賜りました指導教員の岩田誠教授に深謝の意を表します。

本研究の論文の副査を引き受けて下さり、貴重なご意見や疑問点など、本研究を進める上で重要な示唆を与えて下さった中原潔教授、並びに吉田真一准教授に感謝の意を表します。

本研究を行う上で参考にさせて頂いた DyBM のコードを提供して下さいました恐神貴行様に心より感謝いたします

研究室の同輩として、日頃からご支援、ご協力を頂きました、修士課程 2 年の小川友暉氏、渋谷広樹氏に心より感謝いたします。

研究室の後輩として、日頃からご支援、ご協力を頂きました、修士課程 1 年の斎藤あかね氏、田原匡浩氏、福田和馬氏に心より感謝いたします。

最後になりましたが、日頃より心身ともに支えて下さっている深愛なる皆様に心より御礼申し上げます。

参考文献

- [1] Andrew Y. Ng, Jeff Dean, Greg S. Corrado, Kai Chen, Matthieu Devin, Rajat Monga, Marc'Aurelio Ranzato, and Quoc V. Le, "Building high-level feature using large scale unsupervised learning," International Conference on Machine Learning, 2014.
- [2] 北野勝則, "脳のシミュレーションを始めるために," 人工知能, Vol. 30, No. 5, pp. 607–615, Sep. 2015.
- [3] "認知科学と人工知能," <http://milan.elec.ryukoku.ac.jp/~kobori/resume/cog/OLD/cog04.html>, Feb.2016.
- [4] 中山浩太郎, 岩澤有祐, 黒滝紘生, 松尾豊, "Deep Learning の実装と現状," 情報処理, Vol. 56, No.11, pp. 1102–1109, Nov.2015.
- [5] F. Ponulak and A. Kasinski, "Introduction to spiking neural networks : Information processing, learning and applications," Acta Neurobiologiae Experimentalis, VOL. 71, pp.409–433, 2011.
- [6] T. Osogami and M. Otsuka, "Seven neurons memorizing sequences of alphabetical images via spike-timing dependent plasticity," Scientific Reports, vol. 5, 2015.
- [7] "NEST Initiative," <http://www.nest-initiative.org/> Software : About _ NEST, Feb.2016.
- [8] "ニューラルネットワーク入門," <http://www-ailab.elcom.nitech.ac.jp/lecture/neuro/menu.html>, Feb.2016.
- [9] Qiang Yu, et al., "Rapid Feedforward Computation by Temporal Encoding and Learning With Spiking Neurons," IEEE TRANSACTION ON NEURAL NETWORKS AND LEARNING SYSTEMS, VOL. 24, No. 10, p.1539-1552, OCTOBER 2013.

参考文献

- [10] 岡谷貴之, “ディープラーニングによる画像認識 –畳込みネットワークの能力と限界–,” 情報処理, Vol. 56, No.7, pp. 634–639, July2015.
- [11] 岡谷貴之, “ディープラーニングによる画像認識 –基礎と最近の動向–,” オペレーションズ・リサーチ, pp. 196–204.