

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

1205077 梅寄佑樹 【 コンピュータ構成学研究室 】

Object Trajectory Prediction Using Spiking Neural Network

1205077 UMEZAKI Yuki 【 Advanced Computer Engineering Lab. 】

1 はじめに

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え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 [1][2][3]。しかしながら, 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入ってきた入力や入力の抜け落ちに対する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, 図 1 のように, BNN のシミュレーションモデルである LAF(Leaky Integrate and Fire)[1] モデルのニューロンを用いた高精度離散事象シミュレーションと再帰構造を持つ相互結合型の神経回路網形態である BM(Boltzmann Machine) を組み合わせ, フレームジッタや抜け落ちを持つ入力パターンにロバストな SSA-BM (Single Spike Axon Boltzmann Machine) を実装し, 2 値画像に対する物体軌道予測能力の評価を行った。

2 構成方法

提案する SSA-BM は, LAF モデルのニューロンを採用している。これは BNN シミュレーションモデルの 1 つであり, 外的・恒常的膜電流などから膜電位 V_m を増加させ, しきい値を超えると発火させる, という実際の神経細胞に近い動作をする。この発火によって生じるスパイク信号が軸索を通り, 他のニューロンへ伝播される。各ニューロン間は FIFO キュー構造になっており, 伝播遅延を作る。また, 一対のニューロン間の結合は複数の軸索からなる Spike Prop 構造をとり, それぞれピーク値までの到達時間が異なる Alpha 関数によってスパイク信号をニューロンへの影響量へと変換する。これにより, 受け取ったスパイク信号が与える影響が大きくなるタイミングを細かく調整することができる。ニューロンの発火とスパイク信号の到着が与える影響量は 2 種類の ET(Eligibility Trace) によって記録され, それぞれ異なる重みを掛けられた後に膜電位 V_m へ加減算される。

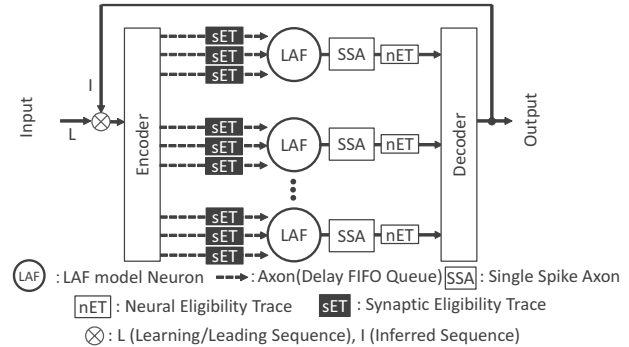


図 1 SSA-BM の構成

SSA-BM のシミュレーションは時間窓間隔を ΔT とした時, ΔT を等分する Δt 間隔で行う。外部からの入力は ΔT 内に 1 つ以下のスパイク信号にエンコードする。受け取った値が 1 の場合は ΔT 内の入力を受け取ったシミュレーションタイミングにスパイク信号があるものとし, 0 の場合はスパイク信号がないとする。ニューロンは信号を受け取り, ΔT 内で 0 回以上発火することが可能だが, 図 2 のようにニューロンの出力スパイク信号として伝播するのは外部から入力を受け取った後に最速で発火したニューロン群のスパイク信号のみとしている。また, 外部への出力はそのニューロン群のみを 1 とし, その他は 0 とする。学習には STDP(Spike Timing Dependent Plasticity) を用い, スパイク信号の到着・発火タイミングを考慮した学習を行っている。学習時はある時刻の入力データに対して次時刻の入力データを出力するように学習する。テスト時は外部から入力データを与えられている間は, そのデータを入力データとして扱い, 外部から与えられなくなった後は前時刻のネットワークの出力を現時刻の入力データとして扱う。

このように, 本研究では, DyBM に LAF モデルを導入し, 高精度離散事象シミュレーションを行うニューラルネットワーク SSA-BM を構成し, 時間的誤差や抜け落ちを持つ入力パターンへのロバスト性を持たせる。

3 評価

提案する SSA-BM を評価するために, 動画内の物体軌道予測課題を用いた。動画は $4(\text{pixel}) \times 4(\text{pixel})$ の 4,




図 2 スパイク信号の伝播例

8, 16 フレームでフレームレートを 100fps とし, その中で 2(pixel)*2(pixel) の正方形の物体が毎フレーム一定の量移動する. LAF モデルの主要パラメタは, 安静時膜電位 $-70(\text{mV})$, 発火しきい値 $-55(\text{mV})$, 細胞膜の電気容量を $250(\text{pF})$, シミュレーション精度 Δt は $1(\text{ms})$ とした. 時間窓は $10(\text{ms})$ とし 10 回のシミュレーションを 1 時間窓とした. 学習は入力フレームに対して次時刻のフレームを出力するように学習することで, 学習した物体軌道パターンに対しての予測能力を持たせた. テスト時は, 学習時に使用したフレームの前半フレームを外部からの入力とし, 動画の残りの後半フレームを予測結果として出力する. その結果と学習時のフレームを比較することで課題に対する性能評価を行う. 学習は常に図 3.(a) を用いる. 評価時は, (a) 学習時の入力パターンと等しいもの (図 3.(a)), (b) 学習時の入力に対して時間的誤差を持つもの (図 3.(b)), (c) 学習時の入力から抜け落ちたフレームが存在するもの (図 3.(c)) を用いた.

表 1 には (a) の前半+後半フレームが 4, 8, 16 の各場合について予測率と必要な学習回数の平均を示す. 表 1 より, SSA-BM は学習済みの時系列パターンに対しては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. 表 2 には (b), (c) の 16 フレームの場合についてのロバスト性を示す. 表 2 より, 今回の条件下では, (b) の場合は 8 フレーム中 5 フレーム以下, (c) の場合は 8 フ

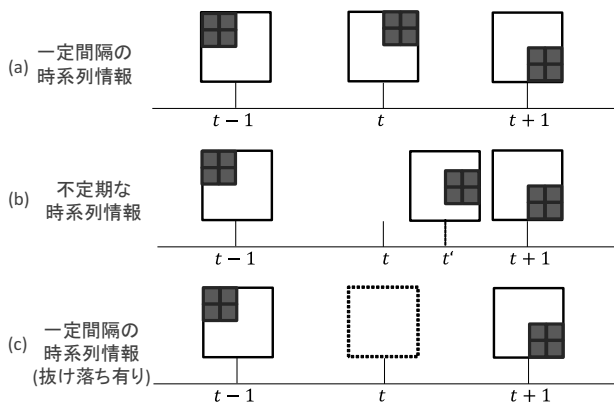


図 3 学習時とテスト時の入力パターン例

表 1 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 (%)	100	100	100
学習回数 (回)	100	200	700

表 2 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 (8 フレーム中)
遅延フレーム (5ms 遅延)	任意の 5 フレーム
抜け落ちフレーム	任意の 4 フレーム

レーム中 4 フレーム以下であれば学習時と微小に異なる入力を与えられても予測が行え, ロバスト性を持つことがわかった. ただし, (b), (c) のどちらの場合でも, 8 フレーム目が例外的なフレームであった場合は予測できなかった.

4 まとめ

本研究では, 入力パターン系列に微小な時間的揺らぎや欠損があっても, それに後続する時系列パターンを予測可能な SSA-BM 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.

SSA-BM は DyBM[3] では不可能な時系列パターンの学習が可能であり, 学習時のパターンから時間的誤差を持つ場合や抜け落ちたフレームが存在する場合に関して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.

参考文献

- [1] 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.
- [2] F. Ponulak and A. Kasinski, “Introduction to spiking neural networks : Information processing, learning and applications,” Acta Neurobiologiae Experimentalis, VOL. 71, pp.409–433, 2011.
- [3] T. Osogami and M. Otsuka, “Seven neurons memorizing sequences of alphabetical images via spike-timing dependent plasticity,” Scientific Reports, vol. 5, 2015.