

ドーパミン変調 STDP を用いた スパイクングニューラルネットワークの学習評価

津村 直宏† 武内 良典‡
Naohiro Tsumura Yoshinori Takeuchi

1. はじめに

現在、機械学習である人工ニューラルネットワーク(ANN)は人気のある学習モデルである[1]。しかし、ANNはニューロン間でやりとりされるデータが一般的に実数値に基づいている。これは、演算器内での計算、および演算器と記憶要素間の情報送信にかなりのエネルギーを消費する可能性がある。そのため ANN は潜在的に大きなエネルギー消費をすることに繋がる。

ANN は生物学的学習に基づいて提案されたにもかかわらず、生物学で観察されるものとは根本的に異なる学習と推論のメカニズムを使用する。ANN はニューロン間で送受される 32 ビットまたは 64 ビットのメッセージを利用するが、生物学的システムのニューロンは 1 ビットの情報に似たスパイクを使用する。さらに ANN の標準的な学習ルールはバックプロパゲーション法であり、各学習ステップでネットワーク全体の同期更新をする必要がある。しかし、生物学的なニューロンの学習ルールは局所的なスパイクイベントに基づく。例えば、スパイクタイミング依存可塑性(STDP)[2]では、シナプスの重みがシナプス前および、シナプス後ニューロンのスパイク活動によって更新される。このローカルイベントベースの学習では ANN の学習プロセスで必要とされる非ローカル送信に必要なエネルギーを必要としない。したがって生物学的ニューロンの学習とローカルイベントベースの計算を厳密に模倣できるスパイクングニューラルネットワーク(SNN)は、特にニューロモフィックプラットフォームに実装されている場合、ANN よりもエネルギー効率を高く実現できる可能性がある。

ANN の学習とは異なり、SNN の学習はスパイクによるため実数値での区別ができず学習が困難である。したがって SNN では効率的な学習アルゴリズムの開発が非常に重要となる。過去 20 年間、この問題に対して多くの研究が行われており、開発されたアプローチのひとつに可塑性ベースの学習がある[3]。可塑性ベースの学習では STDP などを使用して、教師なし学習の方法でパターン認識の特徴を抽出する。

ただし、現実的な SNN モデルをシミュレートするための継続的な課題はスパイク駆動による計算時間の長さである。従来、大規模な SNN のネットワークはハイパフォーマンス CPU クラスタ上で数時間、または数日にわたってシミュレートされていたため、研究ベースが大幅に制限されていた。そのため、より高速なシミュレーションは科学的発見の加速だけではなく、新しいアプリケーションの開発にも役立つ。この研究では生物学的可塑性のルールに基づいて SNN の新たな学習ルールを評価した。パターン認識のためにドーパミン変調 STDP(DA-STDP)ルールを導入した。ニューロン間にドーパミン(DA)が存在する場合、シナプス前およびシナプス後のスパイク活動は狭い時間枠内にある。そのため少ないニューロン数でもハイパフォー

マンスが望める。使用したモデルはベンチマークの手書き数字認識タスク(MNIST データセット)でテストされ STDP と DA-STDP の 2 つの学習ルールを使用してパフォーマンスの評価を行った。またシミュレーションをする上で使用コードは GeNN[4]で CUDA コードを生成し、グラフィックプロセッシングユニット(GPU)を汎用計算機として使用した。

2. モデルの概要

図 1 に示すように 3 層のフィードフォワードスパイクングニューラルネットワークを構築した[10]。これには入力層、隠れ層、および出力層が含まれている。レイヤー構造は Diehl and Cook のモデル[5]を採用した。入力パターンは、対応するピクセルの強度に比例する発火率を持つポアソンスパイクプロセスとしてコード化した。次に、ポアソンスパイク列は all to all の接続で隠れ層の興奮性ニューロンに供給される。興奮性ニューロンから抑制性ニューロンへの接続は one to one で接続を行い、抑制性ニューロンは残りの興奮性ニューロンの抑制を行う。全ての興奮性ニューロンは全ての出力層に接続されている。

学習期間中に入力パターンのラベル情報は 10 個の出力ニューロンによってワンホットコーディングスキームで教師信号に変換がなされる。そのためポアソンスパイクとして 1 つの出力ニューロンのみが発火し、残りの出力ニューロンは休止状態に維持される。

Leaky Integrate-and-Fire(LIF)モデルを使用し、パラメータを生物学的に妥当な範囲内に設定した。静止膜電位 (E_{rest}) は $-65[\text{mV}]$ で設定され、興奮性シナプス (E_E) と抑制性シナプス (E_I) の平衡電圧はそれぞれ $0[\text{mV}]$ と $-100[\text{mV}]$ に設定した。膜電位減衰 (τ) の時定数は $100[\text{ms}]$ とした[6]。膜電位を $V[t]$ としたとき本モデルは式(1)とあらわされる。

$$\tau \frac{dV}{dt} = (E_{rest} - V) + g_E(E_E - V) + g_I(E_I - V) \quad (1)$$

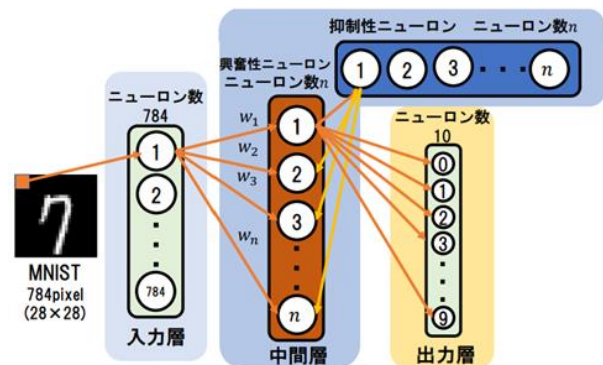


図 1 ネットワークモデル

† 近畿大学大学院, Graduate School of Science and Engineering, Kindai University

‡ 近畿大学, Faculty of Engineering, Kindai University

ここで g_E と g_I は、それぞれ興奮性コンダクタンスと抑制性コンダクタンスである。これらのコンダクタンスは興奮性シナプスと抑制性シナプスの数 (N_E, N_I) と重み (w_{Ei}, w_{Ii}) に依存する。またシナプスコンダクタンス減衰時定数 (τ_{gE}, τ_{gI}) の両方は 1[ms] に等しい。したがって、 g_E と g_I は式(2)(3)のようにあらわせる。

$$\tau_{gE} \frac{dg_E}{dt} = -g_E + \sum_{i=1}^{N_E} \sum_k w_{Ei}^E \delta(t - t_i^k) \quad (2)$$

$$\tau_{gI} \frac{dg_I}{dt} = -g_I + \sum_{i=1}^{N_I} \sum_k w_{Ii}^I \delta(t - t_i^k) \quad (3)$$

ここで、 t_i^k は i 番目のニューロンから k 番目のスパイクの時間である。 $\delta(t)$ はスパイクごとの時間を区別するデルタ関数である。

このニューロンモデルでは膜電位が膜電位閾値 (V_{th}) を超えると、膜電位はリセット電圧 (E_{reset}) の -65[mV] に戻り、発火後 2[ms] の不応期間は発火しない。また膜電位閾値 (V_{th}) は動的閾値を採用している。動的閾値により単一のニューロンの入力シナプスが拡大することによる応答パターンの支配を防ぐ。 V_{th} は定数 ($V_{th}^{const} = 72[\text{mV}]$) と動的変数 (θ) 部分で構成されている。 V_{th} と θ の関係を式(4)(5)に示す。

$$V_{th} = V_{th}^{const} + \theta \quad (4)$$

$$\tau_\theta \frac{d\theta}{dt} = -\theta + \frac{\theta_{initial}}{|\theta - \theta_{initial}|} \sum_k \alpha \delta(t - t_k) \quad (5)$$

ここで τ_θ は θ の時定数であり、 $\theta_{initial}$ は 20[mV] に設定しており、 α は増分の最大値であり、 t_k は k 番目の発火時間である。ニューロンが発火すると θ はわずかに増加する。それ以外の場合は指数関数的に減衰する。また、 θ が大きすぎるとニューロンは発火しない (またはほぼ発火しない) ため、モデルのパフォーマンスに悪影響を及ぼす危険があるため θ の成長は徐々に遅くなるようにしている。[10]

3. 学習ルール

3.1 スパイクタイミング依存可塑性 (STDP)

SNN のシナプス可塑性ベースの学習では基本的に STDP によって重みの更新がされる。STDP は通常式(6)で定義される。

$$\Delta w = \sum_{t_{pre}} \sum_{t_{post}} W(t_{post} - t_{pre}) \quad (6)$$

つまりシナプスの重みの変化 (Δw) は、全てのシナプス前後のスパイク時間 (t_{pre}, t_{post}) の合計である。また重みの増分 (ΔW) は式(7)のように表せる。

$$\Delta W = \begin{cases} A_{pre} e^{-\frac{\Delta t}{\tau_{pre}}} (\Delta t > 0) \\ A_{post} e^{-\frac{\Delta t}{\tau_{post}}} (\Delta t < 0) \end{cases} \quad (7)$$

ここではシナプス前スパイクとシナプス後スパイクの間の時間差 (Δt)、時定数 (τ_{pre}, τ_{post}) そして学習率 (A_{pre}, A_{post}) を用いて ΔW の表現をしている。 Δt と ΔW の関係をグラフで示すと図 2 のようになり、シナプス後(post)ニューロンが発火するほど重みが増加していき、シナプス前(pre)ニューロンが発火するほど重みが減少することが分かる。




図 2 STDP の時間差 (Δt) あたりの重みの更新量 (ΔW)

3.2 ドーパミン変調 STDP (DA-STDP)

実際の脳皮質にはドーパミン (DA) によって変調された STDP を持つことが、海馬と前頭前野でのいくつかの実験で観察されている[7][8]。

シナプス可塑性の DA 変調の重要な側面は、長期増強 (LTP) と長期抑制 (LTD) の強化である。図 3(a) に示す 2 つのニューロンについて考える。STDP には図 3(b) に示すように、シナプスの LTP と LTD の両方が含まれている。シナプス後ニューロンの直前にシナプス前ニューロンを発火させると、シナプス伝達の LTP が発生し、逆順で LTD が発生する。しかし、STDP の LTP および LTD コンポーネントは DA によって変調されると想定するのが妥当である。これは遅延して更新を行う「シナプス適格性トレース」によって機能する。

STDP と DA によって引き起こされる細胞内プロセスの動態は不明であるため、STDP の DA 変調の本質を捉えた最も単純な現象論的モデルを提示する。各シナプスの重み (w) と適格性トレース (c) は式(8)および式(9)によって記述され、細胞外濃度 (d) によって更新される。[9]

$$\Delta c = -\frac{c}{\tau_c} + STDP(\tau) \delta\left(t - t_{\frac{pre}{post}}\right) \quad (8)$$

$$\Delta w = cd \quad (9)$$

d は DA の細胞外濃度を表し、 $\delta(t)$ は c を段階的に増加させるデルタ関数である。それぞれの t_{pre} および t_{post} の時間に発生するシナプス前ニューロンとシナプス後ニューロンの発火は図 3(b) に示す $STDP(\tau)$ ($\tau = t_{post} - t_{pre}$) だけ c を変化させる。図 3(c) にあるように c は時定数 $\tau_c = 1[s]$ で $c = 0$ に減衰する。その間に細胞外濃度 (d) が存在する場合 ($d > 0$)、シナプス後発火が発生するたびに更新を行う。図 3(d) のように各スパイクの更新によりシナプスの重み (w) の段階的な増加をもたらす。

図 3(d) に示すように DA-STDP は w を高めることしかできないため、シナプススケールリングを導入した。ここではパターンが学習され w が式(10)にしたがって正規化された後にシナプススケールリングを実行する。[10]

$$w' = w \frac{\beta N_{in}}{\sum w} \quad (10)$$

N_{in} はすべてのシナプス内の単一ニューロンの数であり、 $\beta \in (0, 1)$ はスケールリング係数である。

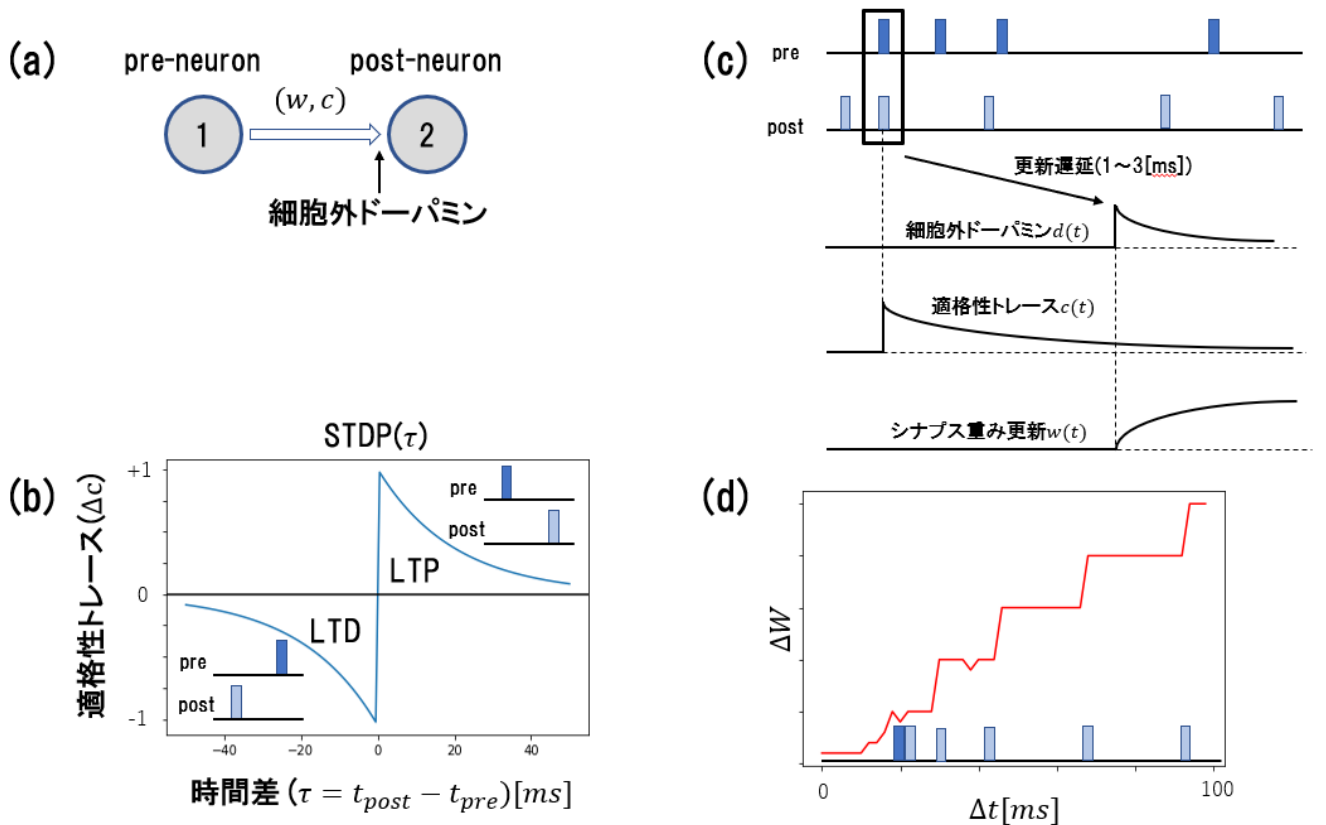


図 3 (a)2 つのニューロン結合。シナプスの重み w および適格性トレース c は細胞外ドーパミンによってゲートされる。(b)STDP ルールの時間差による c の変化。(c)ドーパミン変調による重みの更新。重みの更新量 (Δw) は $d(t)$ と $c(t)$ によって決定される。(d)各スパイクによる更新。

4. 実験と結果

使用した SNN モデルは MNIST データセットを STDP と DA-STDP の 2 つの学習ルールでそれぞれ学習する。MNIST データセットは学習画像 60000 枚とテスト画像 10000 枚で各画像に数字ラベルがセットされた手書き数字認識タスクである。

学習段階では最初に隠れ層のシナプスが学習され、次に出力層のシナプスが学習される。推論段階では重みの大きさが最も大きい出力ニューロンが出力サンプルの推論ラベルとみなされる。実行は SNN シミュレータの GeNN[4]を使用して全ての実験をシミュレートした。

GeNN は NVIDIA GPU でネットワークシミュレーションを行う CUDA コードを生成する、コード生成フレームワークである。GeNN は固定されたグローバルタイムステップを使用してタイムステップ駆動方式で機能する

動作環境は Ubuntu16.04.7LTS を使用。GPU は GeForce GTX 1080 を使用して実験を行った。

モデルパラメータについては、シミュレーションタイムステップを 0.5[ms]に設定して、単一の入力サンプルの提示時間を 350[ms]にし、その後に 150[ms]の休止期間を設定した。全シナプスの初期の重みは[0,0.3]の範囲で均一な分布値に設定した。シナプススケール係数(β)は 0.1 に設定した[10]。

計算時間に繋がるネットワークの計算量はネットワークサイズに比例するので、様々なネットワークサイズに対し

て STDP と DA-STDP の学習ルールを適応して、epoch ごとに学習とテストを行い、認識率を測定した。隠れ層の興奮性ニューロン数[100, 400, 1600, 6400]ごとの epoch を変化させたときの認識率を図 4 に示す。epoch 数 0 は学習を行う前の状態を示す。また、STDP と DA-STDP による 5epoch の総計算時間を興奮性ニューロン数ごとに図 5 に示す。

5. 考察

DA-STDP の有用性を示すために MNIST データセットを用いて学習とテストを行った。図 4 から DA-STDP は興奮性ニューロン数 400 で epoch 数 1 において 91%以上の認識率を達成することができた。STDP の興奮性ニューロン数 400 epoch1 と比較すると 10%以上の差があることが分かる。

DA-STDP で改善される理由として、DA-STDP は 2 つの接続されたニューロンで時間的順序に関係なくスパイクイベントによる重みの更新をすることで特徴の抽出の回数を増やすことが可能となったと考えられる。また、シナプススケール係数によりシナプス全体の重みを安定させ、ニューロンのシナプス内での重みの競合を作成し、より適切なシナプスグループの強化をすることができた。さらに動的閾値メカニズムにより、ニューロンは一致したパターンに対して発火するように強制されていたが、一致しないパターンにはめったに発火せず、特別なクラスのパターンに対するニューロンの選択性が生成された。これらの 3 つのメカニズムを組み合わせることにより DA-STDP はシナプスの更新を強化して効果的な学習を可能にした。

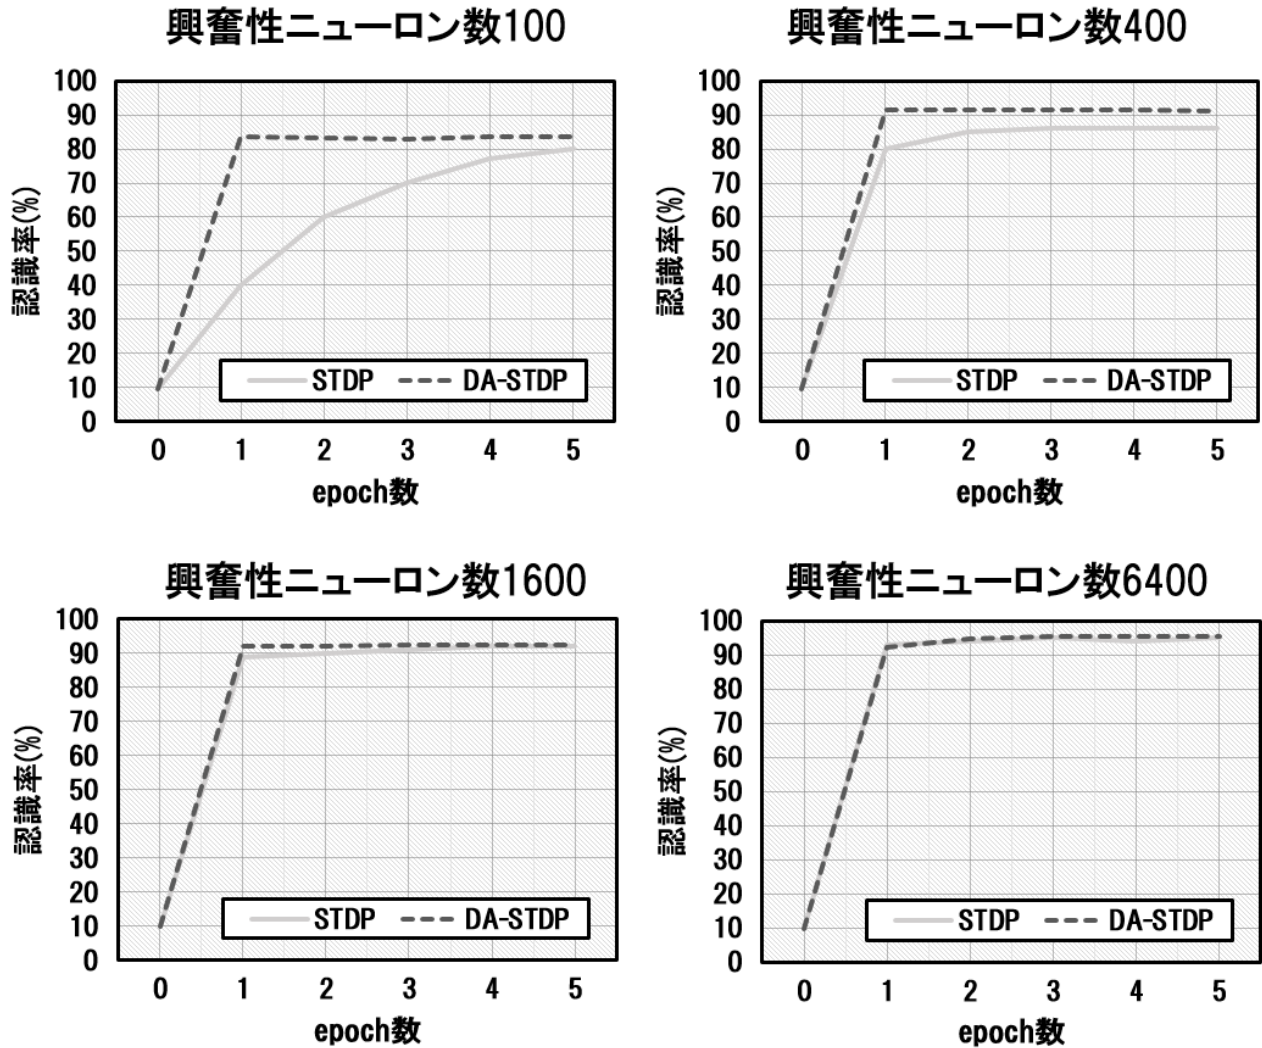


図4 興奮性ニューロン数ごとに示した STDP と DA-STDP による epoch 数ごとの認識率

STDP では認識率 91%に最も早く辿りつくのは図 4 より興奮性ニューロン数 6400 の epoch1 となる。計算時間に注目すると図 5 より DA-STDP の興奮性ニューロン数 400 は STDP による興奮性ニューロン数 6400 のおよそ 35%の計算時間となる事が分かる。

DA-STDP によって少ないニューロン数でのハイパフォーマンスを確認でき、高い認識率を得る学習に対する計算時間の短縮を実現できた。しかし、図 5 より同じ興奮性ニューロン数では STDP の計算時間が短いことが分かる。DA-STDP では高まり続ける重みをスケールアップする必要があり、それに際しての複雑な時空間情報を処理する能力を向上させることが必要である。

6. まとめ

今回の実験では、SNN の学習ルールである STDP と DA-STDP を比較するために、それぞれの学習ルールで MNIST データセットの学習とテストを行った。DA-STDP でシナプスの重みの更新を強化することで少ないニューロン数で高認識率を達成できた。ニューロン数はネットワーク全体の計算量と関係するため、計算時間の短縮に関わる

要素のひとつである。そのため DA-STDP が SNN における計算時間の短縮に有用であることを示した。

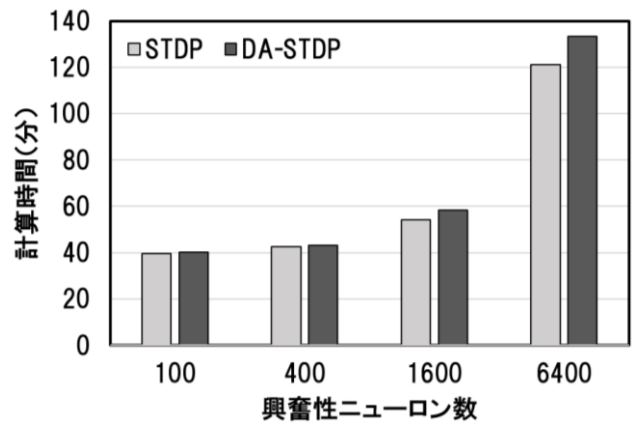


図5 興奮性ニューロン数ごとの計算時間

参考文献

- [1] Hinton G. E. and Salakhutdinov R. R. “Reducing the dimensionality of data with neural networks”, *Science*, Vol. 313, No. 5786, pp. 504-507, 2006.
- [2] Guo-qiang Bi and Mu-ming Poo, “Synaptic modifications in cultured hippocampal neurons: dependence on spike timing, synaptic strength, and postsynaptic cell”, *Journal of Neuroscience*, Vol. 18, No. 24, pp.10464-10472, 1998.
- [3] TavanaeiGhodrati, S. R. Kheradpisheh, T. Masquelier, A. S. Maida.M. “Deep learning in spiking neural networks. “, <https://arxiv.org/abs/1804.08150>, (最終閲覧日:2022/6/22).
- [4] Esin Yavuz, James Turner and Thomas Nowotny, “GeNN: a code generation framework for accelerated brain simulations”, *Scientific reports*, Vol. 6, No.18854, 2016.
- [5] Peter U. Diehl and Matthew Cook, “Unsupervised learning of digit recognition using spike-timing-dependent plasticity”, *Frontiers in Computer Neuroscience*, doi: 10.3389/fncom.2015.00099, 2015.
- [6] T. P. VogelsSprekeler, H. Sprekeler, F. Zenke, C. Clopath, W. GerstnerH. “Inhibitory plasticity balances excitation and inhibition in sensory pathways and memory”, *Science*, Vol, 334, No. 6062, pp.1569-1573, 2011.
- [7] J. Chuan Zhang, P. Ming Lau and G. Qiang Bi, “Gain in sensitivity and loss in temporal contrast of stdp by dopaminergic modulation at hippocampal synapses”, *PNAS*, Vol. 106, No. 31, pp.13028-13033, 2009.
- [8] Hongyu Ruan, Taixiang Saur and W. Dong Yao “Dopamine-enabled anti-Hebbian timing-dependent plasticity in prefrontal circuitry”, *Frontiers in Neural Circuits*, doi: 10.3389/fncir.2014.00038, 2014.
- [9] Eugene M. Izhikevich, “Solving the Distal Reward Problem through Linkage of STDP and Dopamine Signaling”, *Cerebral Cortex*, Vol. 17, Issue 10, pp. 2443–2452, 2007.
- [10] Yunzhe Hao, Xuhui Huang, Meng Dong, Bo Xu, “A Biologically Plausible Supervised Learning Method for Spiking Neural Networks Using the Symmetric STDP Rule”, <https://arxiv.org/abs/1812.06574>, (最終閲覧日 2022/6/22).