

スパイクニューラルネットワークのための適応型重み減衰を取り入れた教師あり STDP 学習

荒木 裕史[†]

山梨大学 大学院医工農学総合教育部[†]

服部 元信[‡]

山梨大学 大学院総合研究部[‡]

1 はじめに

近年、人工知能分野においてスパイクニューラルネットワーク (SNN) と呼ばれる、新たな人工ニューラルネットワーク (ANN) モデルの研究が盛んになってきている。SNN は既存の ANN モデルと比べ、脳神経活動をより精緻に模倣したモデルであり、工学的研究に留まらず、神経科学分野などにおいても重宝されているモデルである。既存の SNN モデル [1] は教師なし学習にもかかわらず、特定のタスクにおいて優れた性能を獲得できているが、学習後のラベル付けコストといった学習の効率面で改善の余地がある。そこで本研究では、SNN のための効率性を重視した新たな教師あり学習法を構築することを目的とする。実験では小さなモデルであっても優れた性能を獲得できるだけでなく、学習の順序を考慮しない、すなわち破局的忘却が生じないモデルの構築が可能であることを示した。

2 SNN

SNN は一般的にスパイクニューロンモデル (SNM) を用いたモデルを指す。SNM には実際の神経細胞活動をどれだけ精緻に模倣するかによって様々なモデルが存在するが、本研究では LIF (Leaky integrate-and-fire) モデルを用いる。LIF モデルは以下の微分方程式で表される。

$$\tau_m \frac{dV(t)}{dt} = (-V(t) + E_{rest}) + I(t) \quad (1)$$

このとき、 $V(t)$ は膜電位、 E_{rest} は静止膜電位、 $I(t)$ は入力電流、 τ_m は時定数である。また、入力電流 $I(t)$ はシナプス前ニューロンの出力スパイク $s(t)$ とシナプス結合荷重 w を用いて以




図1 ネットワーク構成

下のように定義される。

$$\tau_i \frac{dI(t)}{dt} = -I(t) + \sum_{j \in Pre} w_j s_j(t) \quad (2)$$

$$s(t) = \sum_{t^f \in T_S} \delta(t - t^f) \quad (3)$$

ここで Pre と T_S は、それぞれシナプス後ニューロンの集合と発火時刻の集合を示し、 τ_i は時定数を示す。また、 $\delta(t)$ はディラックのデルタ関数である。

ネットワークは先行研究である教師なし STDP (Spike-timing-dependent plasticity) 学習モデル [1] をベースとした構成をとる。図1に示すように、入力層、出力層、側抑制層の3層構造である。また本手法では、教師あり学習のため出力層のニューロンはラベルごとにグループ化されている。

3 重み減衰つき教師あり STDP 学習

ネットワークの学習法として本研究では教師あり STDP 学習を提案する。先行研究のモデルでは、教師なし学習ゆえに学習とは別で出力層ニューロンへのラベル付け作業が存在し、学習効率性の低下の要因になっていたが、本手法ではそれを解消する。図2に示すように正解ラ

Supervised STDP Learning for Spiking Neural Networks with Adaptive Weight Decay

[†] Hiroshi Araki, University of Yamanashi

[‡] Motonobu Hattori, University of Yamanashi

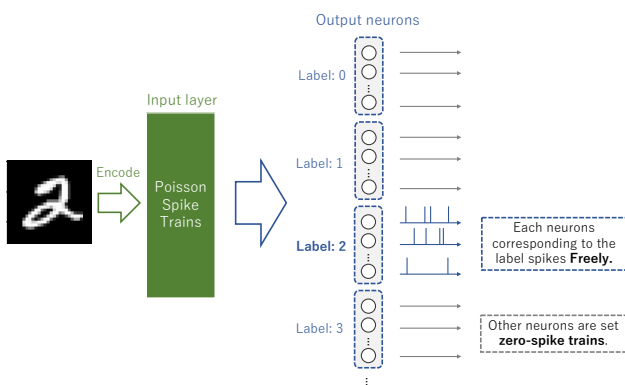


図2 教師あり STDP 学習の概要

ベルを持つニューロンには自由に発火させ、そうでないニューロンには抑制の教師信号を与える形をとる。また本研究では識別の一助として、ここに重み減衰メカニズムを導入する。本メカニズムは以下の式で表される。

$$\tau_w \frac{dw}{dt} = (-w + W_{inh}) \cdot s(t) \quad (4)$$

$$\tau_w = \frac{\tau_{w_0}}{\exp(\alpha(w + \beta))} \quad (5)$$

ここで、 W_{inh} は重みの収束定数で、 τ_{w_0} は時定数基準値、 α, β は減衰係数である。

4 実験

本手法の性能調査を行った。出力層ニューロン数を 100, 400, 1600 個としたときのそれぞれの平均最高テスト精度を、先行研究と比較することで、本モデルの有意性を確認した。なお、各パラメータは予備実験により事前に最適値を調査し、それを用いた。

4.1 実験データ

本実験では手書き数字データセットである、MNIST を学習データ 60,000 枚、テストデータ 10,000 枚に分けて実験を行った。学習回数は 3 エポックとし、計 180,000 枚の学習データを学習させた。また、前処理として実数値画像データをポアソンエンコーダ [2] によって [0, 128]Hz のスパイク列に変換し、入力データとした。

4.2 実験結果

実験結果を表 1 に示す。本実験では、各条件で 5 試行ずつ最大精度を取り、比較を行った。

4.3 考察

結果より、本提案手法で得られたモデルによって、先行研究モデルより大きく精度が改善されることがわかった。実際にいずれの条件においても有意差 ($p < 0.01$) を確認でき、特に小

表 1 各モデルにおける最高テスト精度 (%) の比較

モデル	出力層ニューロン数		
	100	400	1600
Unsupervised	77.22	87.89	88.99
STDP [1]	± 0.467	± 0.411	± 0.480
Supervised STDP (This work)	89.99	93.05	93.99
	± 0.201	± 0.156	± 0.139

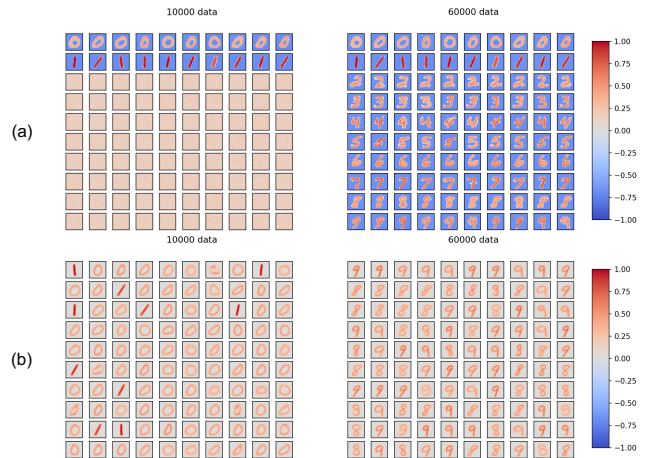


図3 ラベル'1'から'9'まで追加的に学習した場合の (a) 本手法で得られた重みと (b) 先行研究によって得られた重み

きなネットワークでの性能差が顕著であった。また、学習データをラベル'1'から'9'まで順番に与えた場合においても図 3 に示すように破局的忘却を起こすことなく、各ラベルが独立して学習を行うことができる。これはすなわち、学習コストの低下にも繋がる。

5 まとめ

本研究では、SNN のための新たな効率的な学習法を開発することを目的とし、重み減衰メカニズムを導入した教師あり STDP 学習を提案した。本手法では、小さなネットワークであっても十分な性能を得ることができるだけでなく、学習データの順序を考慮しないモデルの構築を可能とした。

参考文献

[1] Diehl, P. U., Cook., M., "Unsupervised learning of digit recognition using spike-timing-dependent plasticity," *Frontiers in Computer Neuroscience* (2015).
 [2] Heeger. D., "Poisson Model of Spike Generation," *Handout, University of Standford*, vol. 5, (2000).