

スパイクニューロンの深層学習への応用

Application of Spiking Neurons to Deep Learning

小西 創[†] 松原 崇[†] 上原 邦昭[†]

So Konishi Takashi Matsubara Kuniaki Uehara

1. はじめに

ディープラーニングは画像認識や音声認識などによく用いられている。ディープラーニングは、脳の神経回路を模したニューラルネットワークの層の数を増やしたものである。ディープニューラルネットワークとも言う。脳を模倣したアルゴリズムの研究自体は昔から進められている。1982年にJ. Hopfieldはニューラルネットワークの一モデルであるホップフィールドネットワークを提案している [1]。これはユニット（ニューロン）間に対称的な相互作用があるネットワークである。1985年にはG. Hintonらによりホップフィールドネットワークの一種であるボルツマンマシンが提案されている [2]。また1986年にP. Smolenskyにより、ボルツマンマシンに改良を加えた、同一層同士のユニットの接続を認めない、制限付きボルツマンマシンも登場している [3]。制限付きボルツマンマシンの概念図を図1に示す。可視層に入力データ x と正解ラベル y を入れて学習させると、隠れ層 h に入力データ x と正解ラベル y の関係を良く表すように、パラメータ (W, U) の値が学習される。 W, U は可視層と隠れ層の間の対称的な結合強度を表す。制限付きボルツマンマシンは2000年代に入って、テキストデータや画像データに関する特徴抽出や、ディープニューラルネットワークを用いた分類問題における訓練段階などで効果を発揮している。また [4] では、ボルツマンマシンによる識別モデルの Discriminative Restricted Boltzmann Machines (DRBM) を提案している。さらに Hinton らは、2006年に、ニューラルネットワークを使用した、次元圧縮のためのアルゴリズムである Autoencoder を提案している [5]。さらに2009年に、Deep Belief Network を提案している [6]。これは、制限付きボルツマンマシンを何層にも重ねて、それぞれ教師なし学習を行い、最終層だけ教師あり学習を行うというものである。この DBN を事前学習に用い、最後に全層に教師あり学習を施したものがディープラーニングの始まりである。

これに対し、神経細胞が発する活動電位を人工的に再現し、これを時間的な波形として再現しようとする仕組みを、スパイクニューラルネットワークという。活動電位とは、なんらかの刺激に応じて細胞膜に生じる一過




図 1: Discriminative Restricted Boltzmann Machines の概念図。可視層に入力データ x と正解ラベル y を入れて学習させると、隠れ層 h に入力データ x と正解ラベル y の関係を良く表すように、パラメータ W, U の値が学習される。 W, U は可視層と隠れ層の間の対称的な結合強度を表す。

性の膜電位のことである。近年、スパイクニューロンに関する様々な研究が行われており、文献 [7] ではスパイクニューロンに関する様々なモデルが紹介されている。スパイクニューラルネットワークは、回路実装コストで、従来の人工ニューラルネットワークより優れているとされる [8]。先行研究 [8] では、DBN を変換して、Integrate-and-Fire Neurons に適応する手法を提案している。また、文献 [9] では、Deep convolutional neural network をスパイクを考慮したハードウェアにマッピングすることのできるスパイクニューラルネットワークへと変換している。このように、スパイクニューラルネットワークのパラメータを決定するためには、学習させたディープニューラルネットワークを変換させることが多い。しかし、これらの方法では、変換による誤差が発生することや、追加の学習が困難であることなどの問題がある。よって、スパイクニューラルネットワークをそのまま学習させる事が好ましい。しかし、スパイクニューラルネットワークの学習法は確立されていない。以上の背景より、本論文では、STDP を用いたスパイクニューラルネットワークの学習を提案する。

[†] 神戸大学 大学院 システム情報学研究科, Kobe University, Graduate School of System Informatics, Kobe, Hyogo 657-0011, Japan

2. 提案手法

2.1 スパイク時刻依存シナプス可塑性

生物の脳は、多数のニューロン (神経細胞) から構成される。ニューロンは、情報処理や情報伝達などの機能を持つ。また、ニューロン間の接合部をシナプスと呼ぶ。シナプスは、化学シナプス、電気シナプスに分類され、化学シナプスには、興奮性シナプス、抑制性シナプスがある。シナプス前細胞が発火すると、興奮性シナプスは、興奮性シナプス後電位 (EPSP; Excitatory Post Synaptic Potential) を発生させ、抑制性シナプスは、抑制性シナプス後電位 (IPSP; Inhibitory Post Synaptic Potential) を発生させる。以下、興奮性及び抑制性に関する変数をそれぞれ添字 E, I で表す。 v_i をニューロン i の電位とすると、シナプス後電位の変化は式 (1) で表される。

$$\frac{dv_i}{dt} = -\frac{1}{\tau_m}(v_i - V_L) - g_i^E(v_i - V_E) - g_i^I(v_i - V_I). \quad (1)$$

ここで、式 (1) の第 1 項はリーク電流を表す。また、式 (1) 中の g_i^X ($X \in \{E, I\}$) はシナプス電流を示し、式 (2) で表される [10]。

$$\frac{dg_i^X}{dt} = -\frac{g_i^X}{\tau_s^X} + \sum_j^{N_X} c_{ij}^{XY} G_{ij}^{XY} \sum_{s_j} \delta(t - s_j^X - d_{ij}^{XY}), \quad X, Y \in \{E, I\}. \quad (2)$$

τ_s^X は興奮性シナプス、抑制性シナプスの衰退時間を表す。 c_{ij}^{XY} は隣接行列の各要素であり、この場合、ニューロン j, i が接続されていれば 1 をとる。 G_{ij}^{XY} は各シナプス間のコンダクタンスを表す行列であり、例えば興奮性シナプス同士のコダクタンスは G_{ij}^{EE} で表される。 t, s_j^X, d_{ij}^{XY} はそれぞれ、現在の時刻、ニューロンの発火時刻、ニューロン j, i の発火時刻の差を表す。シナプスの伝達効率は、シナプスの活動により変化する。この現象はシナプス可塑性と呼ばれ、記憶や学習に重要な役割を持つと考えられている。シグナルを伝える側の細胞であるシナプス前細胞と、伝えられる側のシナプス後細胞がともに高頻度で発火すると、シナプスの伝達効率が增加する。この現象を長期増強 (LTP; Long Term Potentiation) という。また、低頻度の発火などにより、シナプスの伝達効率が低下する現象を長期抑制 (LTD; Long Term Depression) という。またシナプス前細胞と後細胞の発火時間差によっても結合強度に変化が見られることがわかっており、これをスパイク時刻依存シナプス可塑性 (STDP; Spike-Timing Dependent Plasticity) という [11]。

STDP モデルにおけるシナプス前細胞の NMDA 受容体の開口率、あるいは束縛されたグルタミン酸の量を x

とし、シナプス後細胞のカルシウム濃度を y で表すと、それぞれ以下の式 (3),(4) で更新される [11]。

$$\frac{dx_j}{dt} = -x_j/\tau_+ + a_+(x_j) \sum_f \delta(t - t_j^f), \quad (3)$$

$$\frac{dy}{dt} = -y/\tau_- + a_-(y) \sum_n \delta(t - t^n). \quad (4)$$

$\delta(\cdot)$ はデルタ関数であり、 t_j^f 及び t^n はシナプス前細胞及び後細胞の発火時刻である。故に右辺第二項は対応する細胞が発火した時のみ意味を持つ。 $a_+(x_j)$, $a_-(y)$ はそれぞれ発火した際に増える NMDA 受容体の開口率、およびカルシウム濃度の量である。シナプス間の結合強度を w とすると、STDP による w の更新量は以下の式 (5) で表される。

$$\frac{dw_j}{dt} = A_+(w_j)x(t) \sum_n \delta(t - t^n) - A_-(w_j)y(t) \sum_f \delta(t - t_j^f). \quad (5)$$

w は、 $w^{\min} \leq w_j \leq w^{\max}$ の範囲に制限され、 $w^{\min} = 0$ が望ましい。式 (5) の $A_+(w_j)$, $A_-(w_j)$ は関数であり、様々な式で表される [12][13]。 w が大きいほど増加しにくいようなモデルを soft bound と呼び、 w を w^{\max} で打ち切るようなモデルを hard bound と呼ぶ。

文献 [14] では、スパイクニューロンを用いた RBM の学習のための CD(Contrastive Divergence) 法が紹介されている。この手法は STDP の式を参考にしてのもの、STDP の特徴である時間的非対称性を考慮しておらず、また学習フェイズと反学習フェイズの切り替えにも神経科学的な裏付けが乏しい。一方で、文献 [15] はより生体神経に近い学習アルゴリズムを提案しているが、単層ニューラルネットワークであるため、複数の層を必要とする XOR 問題などを解くことができない。また、[16] の手法は多層であるが、最終層以外は学習を行っていない。文献 [15][16] は、カルシウム濃度を考慮した STDP によるモデルを提案しているが、いずれも外部の入力を必要とする学習フェイズしか存在しない。

2.2 ドーパミンによる結合強度の変化

ボルツマンマシンでは、学習フェイズで入力と教師データを与え、その活動の相関に応じて結合を強める、また、入力も教師データも与えない反学習フェイズで現れる相関に応じて結合を弱める。このように、接続を強めることにより必要な相関を学習することと、接続を弱めることにより不要な相関を消去することで、適切な相関を学習する。しかし、このような二段階の学習法は神経科学

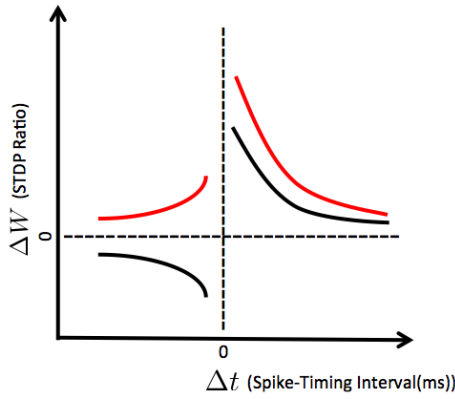


図 2: ドーパミンを与えた時の STDP の変化 [18]. 横軸は時間の変化量 Δt を表し、縦軸は結合強度の変化量 ΔW を表す。黒の実線は通常の STDP の変化を表し、赤線はドーパミンを与えた時の STDP の変化を表す。

的な裏付けが乏しい。また、二つのニューロン間の結合強度は双方向とも同じである必要があり、これも神経科学の分野における実験結果と一致しない [17]。またボルツマンマシンにおいては、教師データが入力されているニューロン y と、他のニューロン h が同時に発火した場合、 y と h の活動には相関があるので、 y と h の間の結合 $w(y, h)$ が同じように強められ、双方向の結合が維持される。一方、STDP では $w(y, h)$ が強くなると $w(h, y)$ が弱くなるので、単方向の結合が生じる。このように、ボルツマンマシンの学習アルゴリズムは多くの点で生体神経系と異なる。

本論文では、ドーパミンの作用を考慮した STDP モデルを用いて、以上の問題を解決する。ドーパミンを与えると、式 (5) の $A_+(w_j)$ はドーパミンを与えない場合に比べて大きくなり、 $A_-(w_j)$ はマイナスからプラスへと変化することが知られている [18]。つまり、ドーパミンを与えると LTD が起こるようなタイミングであっても、弱いながら LTP が起こる [18]。ドーパミンを与えた時の STDP の変化を図 2 に表す。図 2 で、黒の実線が通常の STDP の変化を表すのに対し、赤線はドーパミンを与えた時の STDP の変化を表す。教師データが与えられているときはドーパミンを与え、そうでない時はドーパミンを与えなければ、二段階の学習を再現することができると思われる。

3. 実験

本論文では、ドーパミンの作用を考慮した STDP モデルを用いることにより、スパイクニューラルネットワークに対し、DRBM に類似した学習を実現できることを示す。まず例として、シナプス前細胞、後細胞が




図 3: シナプスモデルの概念図。 W_{ij} , W_{ji} はシナプス i , j 間の結合強度を表す。




図 4: シナプスの発火状態およびシナプス間の結合強度の変化。 v_i , v_j , W , t はそれぞれシナプス i , j の電位、シナプス間の結合強度、時刻を表す。上の二つのグラフはそれぞれシナプス i , j の電位の変化を表す。下の二つのグラフはそれぞれドーパミンを与えていない時、与えた時の結合強度 W_{ij} , W_{ji} の変化を表す。

それぞれ 1 個である簡単なモデルについて述べる。モデルの概念図は図 3 である。シナプス i から j への結合強度を W_{ij} 、シナプス j から i への結合強度を W_{ji} で表している。 v_i , v_j , t をそれぞれシナプス i , j の電位、時刻としたときの、シナプスの発火状態およびシナプス間の結合強度の変化を図 4 に示す。上の二つのグラフはそれぞれシナプス i , j の電位の変化を表している。下の二つのグラフはそれぞれドーパミンを与えていない時、与えた時の結合強度 W_{ij} , W_{ji} の変化を表している。図 4 から、ドーパミンを与えていない場合に結合強度がマイナスに変化している部分が、ドーパミンを与えるとプラスへと変化していることがわかる。

より詳細な結果は当日発表する。

参考文献

[1] John J Hopfield. Neural networks and physical systems with emergent collective computational

- abilities. *Proceedings of the National Academy of Sciences*, Vol. 79, No. 8, pp. 2554–2558, 1982.
- [2] David H Ackley, Geoffrey E Hinton, and Terrence J Sejnowski. A learning algorithm for boltzmann machines. *Cognitive Science*, Vol. 9, No. 1, pp. 147–169, 1985.
- [3] Paul Smolensky. Information processing in dynamical systems: Foundations of harmony theory. In *Parallel Distributed Pro: Explorations in the Microstructure of Cognition, Volume 1: Foundations*. MIT Press, 1986.
- [4] Hugo Larochelle and Yoshua Bengio. Classification using discriminative restricted boltzmann machines. In *Proceedings of the 25th International Conference on Machine Learning*, pp. 536–543, 2008.
- [5] Geoffrey E Hinton and Ruslan R Salakhutdinov. Reducing the dimensionality of data with neural networks. *Science*, Vol. 313, No. 5786, pp. 504–507, 2006.
- [6] Geoffrey E Hinton. Deep belief networks. *Scholarpedia*, Vol. 4, No. 5, p. 5947, 2009.
- [7] Eugene M Izhikevich. Which model to use for cortical spiking neurons? *IEEE Transactions on Neural Networks*, Vol. 15, No. 5, pp. 1063–1070, 2004.
- [8] Peter O’Connor, Daniel Neil, Shih-Chii Liu, Tobi Delbruck, and Michael Pfeiffer. Real-time classification and sensor fusion with a spiking deep belief network. *Frontiers in Neuroscience*, Vol. 7, No. 178, 2013.
- [9] Yongqiang Cao, Yang Chen, and Deepak Khosla. Spiking deep convolutional neural networks for energy-efficient object recognition. *International Journal of Computer Vision*, Vol. 113, No. 1, pp. 54–66, 2015.
- [10] Naoki Hiratani, Jun-Nosuke Teramae, and Tomoki Fukai. Associative memory model with long-tail-distributed hebbian synaptic connections. *Frontiers in Computational Neuroscience*, Vol. 6, No. 102, 2012.
- [11] Takumi Uramoto and Hiroyuki Torikai. A calcium-based simple model of multiple spike interactions in spike-timing-dependent plasticity. *Neural Computation*, Vol. 25, No. 7, pp. 1853–1869, 2013.
- [12] Matthieu Gilson and Tomoki Fukai. Stability versus neuronal specialization for stdp: long-tail weight distributions solve the dilemma. *PLoS One*, Vol. 6, No. 10, pp. 1–18, 2011.
- [13] Mark CW Van Rossum, Guo Qiang Bi, and Gina G Turrigiano. Stable hebbian learning from spike timing-dependent plasticity. *The Journal of Neuroscience*, Vol. 20, No. 23, pp. 8812–8821, 2000.
- [14] Emre Neftci, Srinjoy Das, Bruno Pedroni, Kenneth Kreutz-Delgado, and Gert Cauwenberghs. Event-driven contrastive divergence for spiking neuromorphic systems. *Frontiers in Neuroscience*, Vol. 7, No. 272, 2013.
- [15] Joseph M Brader, Walter Senn, and Stefano Fusi. Learning real-world stimuli in a neural network with spike-driven synaptic dynamics. *Neural Computation*, Vol. 19, No. 11, pp. 2881–2912, 2007.
- [16] Michael Beyeler, Nikil D Dutt, and Jeffrey L Krichmar. Categorization and decision-making in a neurobiologically plausible spiking network using a stdp-like learning rule. *Neural Networks*, Vol. 48, pp. 109–124, 2013.
- [17] Sen Song, Per Jesper Sjöström, Markus Reigl, Sacha Nelson, and Dmitri B Chklovskii. Highly nonrandom features of synaptic connectivity in local cortical circuits. *PLoS Biology*, Vol. 3, No. 3, 2005.
- [18] Ji-Chuan Zhang, Pak-Ming Lau, and Guo-Qiang Bi. Gain in sensitivity and loss in temporal contrast of stdp by dopaminergic modulation at hippocampal synapses. *Proceedings of the National Academy of Sciences*, Vol. 106, No. 31, pp. 13028–13033, 2009.