RF-005

ポピュレーションコーディングを適用した SpikeProp ネットワークの耐ノイズ性の向上
Improve Tolerance for Noise in SpikeProp Network with Population Coding

新 友太† 高瀬 治彦† 川中 普晴† 鶴岡 信治‡
Yuta Shin Haruhiko Takase Hiroharu Kawanaka Shinji Tsuruoka

1 はじめに

近年, ユニット間の情報伝達にスパイク (パルス) を用いるスパイキングニューラルネットワーク (SNN: Spiking Neural Network) の研究が盛んに行われている [1]．特に，半導体の製造技術・計算機の速度の向上により，パターン認識等に利用した事例も数多く報告されている．SNN と一口にいっても，さまざまなモデルがある．応用の観点から重要になるのが，情報表現手法である．これには大きく分けて (1) スパイクの密度によるもの，(2) スパイクのタイミングによるものの二種がある．それぞれに得失はあるものの，応答の早さの観点からは，後者が好ましいとされている [2]．これは，スパイクの密度を観測するためには時間がかかるためである．

スパイクのタイミングにより情報表現を行う SNN の学習法として，さまざまなものが提案されている [3], [4]．特に，階層型の SNN において誤差逆伝搬に基づく学習法として SpikeProp が提案されている [5]．これは，階層型のネットワークにおいて，時間遅れの学習を行うことなく出力スパイクのタイミングを学習できるため，その実装が容易であるという特徴を持つ．その論文の中で，入力側の情報表現手法としてポピュレーションコーディングを利用することで，ネットワークの学習能力が向上し，計算精度の低いユニットを用いた場合でも学習が可能になることが示されている．これは，一つの入力信号を複数の信号を用いて表すことで，個々の信号の低い精度を補う手法である．その論文では指摘されていないが，個々の入力信号に対して敏感に反応できるようになった結果，観測ノイズ等による入力信号のゆらぎに対して敏感になりすぎる可能性がある．

本論文では，SpikeProp において，ポピュレーションコーディングを導入することで低下する耐ノイズ性能を回復する方法について検討する．なおこの際，ポピュレーションコーディングを導入することで得た効果は，できるだけ失わないようにする．具体的には，シグモイド型のユニットを使用した古典的なニューラルネットワークの入出力関係の改善に効果があった荷重減衰 (WD:Weight Decay)[6] を導入することを提案し，その効果を検証する．

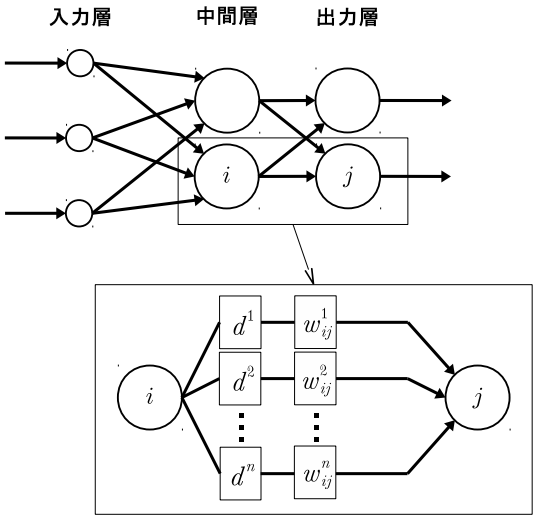

図 1 SpikeProp のネットワーク構造

2 SpikeProp とポピュレーションコーディング

この章では，Bothe らにより提案された SpikeProp および，SpikeProp に適用したポピュレーションコーディングの概略を述べる．

2.1 SpikeProp

SpikeProp とは，Bohte らにより提案された階層型の SNN およびその教師有りの学習法である [5].

ネットワーク構造は，各ユニット間の結合が 1 本ではなく複数本 (n 本) あること点を除けば，一般的な階層型ネットワークと同様である (図 1 参照)．図中，w_{ij}^k はユニット i からユニット j への結合のうち k 番目のものの結合荷重，d^k は各ユニット間の結合のうち k 番目のものの時間遅れを表す.

ネットワークを構成するユニットは，積分発火型のユニットでありその内部状態 x_i は式 (1)，(2) に従い変化する.

$$x_i = \sum_{j\in\Gamma_i}\sum_{k=1}^{n} w_{ji}^k \epsilon(t - t_j - d^k), \tag{1}$$

$$\epsilon(t) = \begin{cases} \dfrac{t}{\tau}\exp(1-\dfrac{t}{\tau}) & (t \geq 0) \\ 0 & (t < 0). \end{cases} \tag{2}$$

ここで，Γ_i はユニット i へ接続しているユニットの集合，t_j はユニット j の発火時刻，τ は各ユニットの時定数を表す．また，$\epsilon(t)$ をスパイク応答関数と呼ぶ．各ユニット

† 三重大学大学院 工学研究科
‡ 三重大学大学院 地域イノベーション学研究科

は，内部状態があらかじめ定められたしきい値 θ を最初に超えたときに発火する．接続先のユニットへは，発火時刻が伝達される．

SpikeProp では，出力層ユニットの発火時刻を，誤差逆伝搬に基づいて学習する．具体的には，式 (3) により定められた誤差 E を，式 (4) に従い結合荷重を調整することで，減少させてゆく．

$$E = \sum_{p\in P}\sum_{o\in O}\frac{1}{2}\left(t_o^p - \hat{t}_o^p\right)^2. \tag{3}$$

$$\Delta w_{ij}^k = -\eta\frac{\partial E}{\partial w_{ij}^k}, \quad w_{ij}^k \leftarrow w_{ij}^k + \Delta w_{ij}^k \tag{4}$$

ここで，P は教師パターンの集合，O は出力層ユニットの集合，t_o^p はパターン p でのユニット o の発火時刻，$\hat{t}_o^p$ はパターン p でのユニット o の理想的な発火時刻，正の定数 η は学習率を表す．

2.2 ポピュレーションコーディング

Bothe らは文献において，SpikeProp の学習能力を高める手法として，ポピュレーションコーディング (PC:Population Coding) を導入している．これは，一つの信号値を，複数の信号値の組み合せで表現する手法である．これにより，ネットワークは入力信号の微少な違いを検知しやすくなり，学習能力が向上する．

PC により信号 x を m 個の信号 $(x_1, x_2, \cdots, x_m)$ に変換する手順は以下のとおりである．

1. x の最大 $I_{\max}$ および最小 $I_{\min}$ を求める．
2. m 個の受容野 $T_i(I)\quad (i = 1, 2, \cdots, m)$ を設定する．

$$T_i(I) = \exp\frac{-(I-\mu(i))^2}{2\delta^2}, \tag{5}$$

$$\mu(i) = I_{\min} + \frac{2i-3}{2}\frac{I_{\max}-I_{\min}}{m-2}, \tag{6}$$

$$\delta = \frac{1}{\beta}\frac{I_{\max}-I_{\min}}{m-2}. \tag{7}$$

3. 各受容野の入力 x に対する応答 $T_i(x)$ を得る．
4. 各応答を $0, 1, \cdots, 9$, 発火しないの 11 段階に変換する．なお，$T_i(x) = 1$ なら 0 へ，$T_i(x) = 0$ なら発火しないへと変換する．これは，より早い入力を，より強い入力と見なすためである．
5. 変換後の値を，PC の結果とする．

例えば，入力の値域が $[1.5, 4.5]$ である場合，1.8 を 5 個の信号に変換した結果は，$(6, 2, *, *, *)$ となる (図 2 参照)．なお，「*」は発火しないことを意味する．

2.3 ポピュレーションコーディングの効果

Bohte らは，PC を導入した SpikeProp により，連続値入力を要求する問題を時間分解能が低いニューロンを用いても学習できたこと，また，シグモイド型のユニットを用いた BP ネットワークと比べても少ない学習回数で

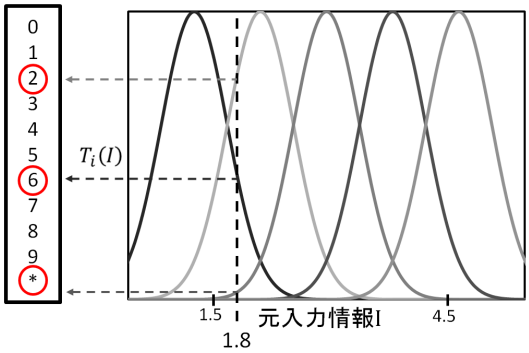

図 2　ポピュレーションコーディングによる変換例

学習できたことを報告している．これは，微少な入力の差がいくつかの信号の変動をもたらすため，ネットワークがその微妙な差を捕らえることが可能になるためだと考えられる．実際，前節の最後で示した例と同様に，1.9 を PC で変換した結果は $(7, 1, 9, *, *)$ となる．これを 1.8 を変換した結果と比べると，5 個の値のうち 3 個の値が異なっている．1.8 や 1.9 をそのまま入力する場合と比べ，PC により変換することで，これらの値を区別することが容易になる．

しかし，この効果により，区別すべき小さな差を拡大するだけでなく，区別しなくても良い小さな差まで拡大してしまう可能性がある．これは，入力の観測ノイズ等による微妙なゆらぎに対して，敏感になりすぎる場合があることを意味する．詳しくは 4 章で示すが，ネットワークの入力信号に対する耐ノイズ性は，PC を適用することで低下している．

3 耐ノイズ性の回復

この章では，PC により向上した学習能力を維持したまま，PC により失われた入力信号に対する耐ノイズ性を回復する手法について検討する．ここでは，シグモイド型のユニットを用いたニューラルネットワークの入出力関係の改善に効果があった荷重減衰に着目する．

3.1 荷重減衰

シグモイド型のユニットを用いた階層型ネットワークにおいて，その入出力関係を改善する学習法として，荷重減衰がしばしば用いられる．これは，不要な結合荷重が 0 に近付くように学習することで，モデルの冗長な自由度をなくし，過学習を抑制したり，汎化能力や耐ノイズ性の向上させるものである．具体的には，BP 法による学習の際に，誤差 E そのものではなく結合荷重の値に関するペナルティ項を加えたものを，学習評価関数 E' として用いることで，誤差及び結合荷重が小さいネットワークを得ようとするものである．この結果，不要な結合の結合荷

重のみが 0 に近づく．

$$E = \sum_{p \in P} \sum_{o \in O} \frac{1}{2} \left(y_o^p - \hat{y}_o^p \right)^2, \tag{8}$$

$$E' = E + \frac{\rho}{2} \sum_{w \in W} w^2. \tag{9}$$

ここで，W は全結合荷重の集合を，ρ はペナルティ項の効果の強さ表す．

このとき，結合荷重の更新量は，次のようになる．

$$w_{ij} \leftarrow w_{ij} - \eta \left(\frac{\partial E}{\partial w_{ij}} + \rho w_{ij} \right). \tag{10}$$

3.2 SpikeProp への荷重減衰の適用

SpikeProp に荷重減衰を適用した場合，その直接的な効果は各ユニットの内部状態の時間変化 $x_i(t)$ に現れる．各ユニットの発火時刻は，$x_i(t)$ がしきい値を超えた時刻であるので，$x_i(t)$ が入力の微小な変化に対して過剰に変形しなければ，入力の揺らぎに対する耐性が向上する．

内部状態は多数のスパイク応答関数の重ね合わせである (式 (1) 参照)．荷重減衰を適用しない場合，各ユニットが発火するごとに n 個のスパイクが接続先のユニットに伝達される．さらに PC を適用することで，一つの入力信号が複数 (m 個) の信号へと分散される．これは，入力からネットワークの出力に至る経路が，他のネットワークと比べても多くなることを意味する．その結果，PC を適用した SpikeProp ネットワークでは，入力のわずかな変化が，内部状態 $x_i(t)$ に対して大きな影響を与える可能性がある．荷重減衰により結合荷重が 0 に近づくと，接続先のユニットに伝達されるスパイクが実質的に減少するため，その影響を軽減できると考える．また，荷重減衰では，全ての結合荷重を一律に小さくするのではなく不要な結合荷重のみが小さくなるため，入力パターンの識別能力は維持される．

SpikeProp に荷重減衰を適用する場合，式 (3) の E を用いて，式 (10) に従い結合荷重を更新する．

4 実験

この章では，PC を適用した SpikeProp ネットワークに対して荷重減衰を適用する効果を検証する．具体的には，(1)PC を適用することで減少した学習回数を維持できるか，(2) 入力信号のノイズへの耐性は向上するかの 2 点について検証する．

4.1 実験条件

実験は，簡単なパターン認識の問題を対象に行う．対象とするパターンセットには，Iris データセットおよび Wine データセットを用いた．これらは，機械学習のベンチマーク問題 [7] としてしばしば用いられる．Iris データセットは，実数のみの 4 入力から 3 個のクラスを識別する問題であり，150 パターンのデータが用意されている．Wine データセットは，実数と整数が含まれる 13 入力から 3 個のクラスを識別する問題であり，178 パターンのデータが用意されている．学習にはランダムにそれぞれの半分のパターン，Iris データセットでは 75 個，Wine データセットでは 88 個のパターンを学習に用いて，その組み合わせを変えた．これは，さまざまな教師パターンに対しての検証を意図したものである．PC を適用しない場合は，教師発火時刻 14 より大きいデータを含む入力は $[0, 10]$ に正規化しそれを入力時刻としてネットワークに入力した．ネットワークの出力ユニットは各クラスに対応づけて 3 個用意し，最も早く発火したユニットに対応したクラスを識別結果と見なした．

表 1　実験条件

	Iris	Wine
入力ユニット数	5(PC 無) 25(PC 有)	14(PC 無) 79(PC 有)
中間ユニット数	10	10
出力ユニット数	3	3
副結合数	16	16
発火しきい値	40	80
PC で使う山の数	6	6
PC の定数 β	1.2	1.5
学習率 η	1.0(PC のみ) 0.5(その他)	1.0
WD の定数 ρ	0.01	0.01

ネットワークの概略は表 1 に示す．表中，PC はポピュレーションコーディング，WD は荷重減衰を意味する．学習時には，当該のクラスに対応するユニットの教師発火時刻は 10，そうでないユニットの教師発火時刻は 14 とした．式 (3) による E が，1 パターンあたり平均 2 以下になったとき学習終了とした．また，2,000 回学習してもその条件を満たさなかった場合は，学習失敗と見なした．学習後のネットワークの評価時に入力に加えるノイズはガウスノイズとし，標準偏差を変えることでノイズの強さを変化させた．実験結果は，各条件・3 通りの学習パターンの選び方に対して，それぞれ 20 種の $[-2, 8]$ の一様乱数により初期荷重を設定した 60 通りのネットワークの結果を平均したものを示す．ただし，負の値を持つ結合荷重はある一つの中間層ユニットから出力層への結合荷重のみがとることができる．

比較は，通常の SpikeProp，PC のみを適用した SpikeProp，PC および WD を適用した SpikeProp の 3 種のネットワークを比較した．また，PC の効果を明らかにするため，各ユニットの発火時刻を低精度 (0.2s 単位) で求めた．

表 2　低精度での学習失敗回数 (全 60 回中)

教師信号	Iris	Wine
通常	5	0
PC のみ	0	0
PC+WD	0	0

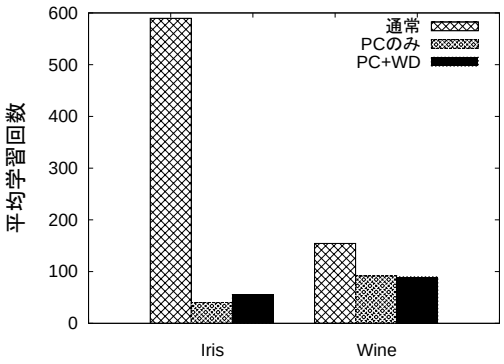

図 3　平均学習回数

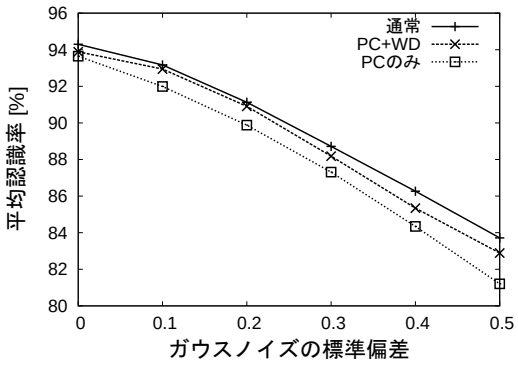

図 4　Iris データセット認識成功率

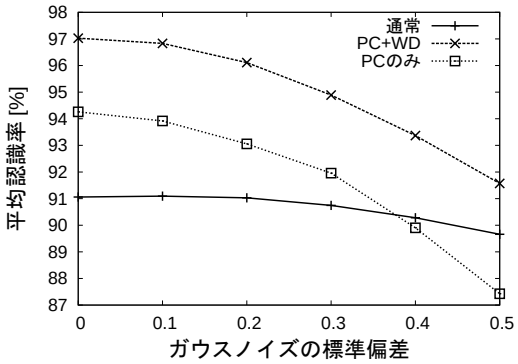

図 5　Wine データセット認識成功率

4.2　学習回数に関する評価

まず，学習成功回数・学習回数について検討する．学習した 60 通りのネットワークについて，表 2 に，学習失敗数を示す．また図 3 に，学習に成功したものについて，それらの平均学習回数を示す．

これらの結果より，以下のことが判る．PC を導入しない場合，他の手法と比べて多い学習回数および，低演算精度のもとでの学習失敗回数の増加が見られた．これらは，PC を導入することで学習回数の減少，学習能力の向上がもたらされるとした Bohte らの結果を支持していると言える．加えて，荷重減衰を導入することにより、これらの点において性能低下が生じなかったことも確認できた．

4.3　入力のノイズへの耐性に関する評価

次に，学習後のネットワークにおける入力信号のノイズによる揺らぎに対する耐性について検討する．図 4，図 5 にネットワークの認識率と入力に加えたノイズの強さ (標準偏差) との関係を示す．

Iris データセットの場合，ノイズの標準偏差が 0，つまりノイズがないときの認識率は，3 種のネットワーク間で有意 ($p < 0.01$) な差が無かった．入力信号がノイズで揺らぐことで，ノイズの強さに応じて認識率が低下している．認識率の低下は，通常のネットワークが最も少なく，以下，PC+WD の場合，PC のみの場合の順に大きくなった．通常の場合と PC のみの場合を比較すると，ノイズの標準偏差が 0.1 の時点から，2 者の認識率の間に有意な差が生じていた．

Wine データセットの場合，ノイズがないときの認識率は，3 種のネットワーク間で有意な認識率の差があった．ノイズの強くなった時の認識率の低下は，通常のネットワークが最も少なく，以下，PC+WD の場合，PC のみの場合の順に大きくなった．PC のみの場合は，ノイズが無い時点での認識率が向上したため，多少の認識率の向上が見られるが，標準偏差 0.5 の時点では，他の 2 手法と比べて大きく認識率が低下した．PC+WD の場合は，ノイズが無い時点での認識率がさらに向上し，ノイズの標準偏差が 0.5 の時点まで通常のネットワークと比べて高い認識率を得ることができた．

図 4，5 において，3 種のネットワークの認識率の関係が異なるように見えるが，これは学習パターンの違いにより生じた無ノイズ時の認識率の違いによるものであると考えられる．いずれの結果も，通常のネットワークと比較して PC のみを導入したネットワークは，入力信号がノイズにより揺らぐことで，その認識率を大きく低下させていることが判る．さらに，WD を PC に併せて適用することで，その低下の度合いを弱め，通常のネットワークに近い認識率を得ることができたと言える．

ここで，これらの効果は荷重減衰によりもたらされたものであるかどうかを確認するため，もう一つ実験を行った．実験条件はこれまでの実験と同一とし，比較対象に $[-2, 4]$ の一様乱数で結合荷重を初期化したネットワーク

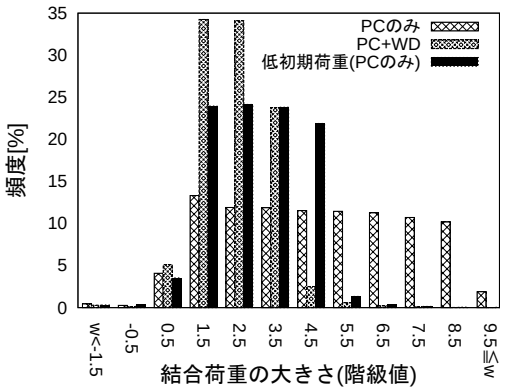

図 6　Iris データセット学習後の結合荷重のヒストグラム

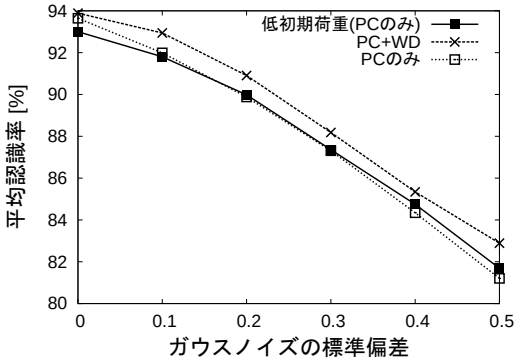

図 7　低初期荷重の結果を含む認識成功率 (Iris)

に PC のみを適用したものを加えた．これは，これまでの実験と比べより絶対値の小さな結合荷重から学習することでネットワーク全体の結合荷重が小さめになることを期待したものである．結合荷重が小さくなるだけで良ければ，このネットワークでも耐ノイズ性向上の効果を確認できるはずである．

図 6 に Iris データセットを学習した後のネットワークの結合荷重のヒストグラムを示す．「低初期荷重 (PC のみ)」が追加したネットワークに対する結果である．荷重減衰を適用した場合には及ばないものの，低初期荷重から学習することで，そうでない場合と比べ結合荷重が全体的に小さくなったことが確認できる．このネットワークにおけるノイズの標準偏差と認識率の関係を図 7 に示す．図中，他の 2 つの結果は図 4 のものと同一である．「低初期荷重 (PC のみ)」の結果は，どちらかというと PC のみの場合に近い変化をしている．また，Wine データセットに対しても同様の傾向の結果が得られた．

これらの結果より，小さな初期結合荷重から学習することで，学習後のネットワークの結合荷重の大きさを小さくすることはできたが，耐ノイズ性は向上しなかったことが判る．これは，荷重減衰により不要な結合のみを小さくしなければ，耐ノイズ性が向上しない間接的な証拠となる．

4.4　実験のまとめ

以上の実験結果より，PC を用いる SpikeProp ネットワークに荷重減衰を適用することで，少ない学習回数と，入力信号に対する高いノイズ耐性が両立することが示された．さまざまな教師パターンを用いたことから，これら以外の様々なパターンについても有効であることを示唆していると考える．また，この効果は単に結合荷重を小さくすることでは得られず，荷重減衰によりもたらされたものであった．

5　まとめ

本稿ではポピュレーションコーディングにより低下する SpikeProp ネットワークの性能を回復するための手法について検討した．時間分解能が低いニューロンを用いる際，ポピュレーションコーディングは有効であるが，入力信号に含まれるノイズに対して性能が低下する．そこで荷重減衰も同時に適用することで，観測ノイズなどによる入力信号のゆらぎによる性能低下の軽減と高い学習能力の維持を両立できることを実験により確認した．

参考文献

[1] Wolfgang Maass and Christopher M. Bishop : Pulsed Neural Networks, The MIT Press, 1998.

[2] Sander M. Bohte: The evidence for neural information processing with precise spike-times: A survey, Natural Computing, Vol. 3, pp. 195–206, 2004.

[3] Andrzej KASIŃSKI and Filip PONULAK : Comparison of Supervised Learning Methods for Spike Time Coding in Spiking Neural Networks, International Journal of Applied Mathematics and Computer Science, Vol.16, No. 1, pp.101–113, 2006.

[4] 黒江康明：スパイキングニューラルネットワーク — 学習法を中心として，システム／制御／情報，Vol.48, No.2, pp.57–62, 2004.

[5] S. M. Bohte, J. N. Kok, and J. A. La Poutré : Error-backpropagation in temporally encoded networks of spiking neurons ,Neurocomputing 48,pp.17-37 (2002)

[6] D. C. Plaut, S. J. Nowlan and G. E. Hinton : Experiments on learning by back propagation, Technical Report CMU-CS-86-126, Carnegie-Mellon University, 1986.

[7] National Science Found : UCI Machine Learning Repository,
http://archive.ics.uci.edu/ml/ (参照:2012-03-02)