

修士論文

SpikePropネットワークにおいて  
誤差の振動を抑制する学習法

平成23年度修了

三重大学大学院工学研究科

博士前期課程 電気電子工学専攻

若松 俊希



三重大学大学院 工学研究科

# 目次

第1章 はじめに	1
第2章 SpikeProp	4
2.1 スパイキングニューロン	4
2.2 ネットワーク構造	6
2.3 学習法	8
2.4 学習過程における誤差の振動	9
第3章 提案法	12
3.1 直線探索法	12
3.2 誤差逆伝搬法と直線探索法の組み合わせ	13
3.3 探索範囲の選択	15
第4章 実験	17
4.1 実験条件	17
4.2 実験結果	19
4.3 実験のまとめ	25
第5章 まとめ	26
謝辞	27
参考文献	28
発表論文	34

# 第1章 はじめに

コンピュータ工学が多大な進歩を遂げ、現代の社会において、コンピュータの役割は非常に大きなものとなっている。二十一世紀は情報化社会といわれ、産業や工学だけでなく、我々の日常生活においてもコンピュータが担う役割は大きい。しかし、現在の性能の高いノイマン型コンピュータでも、人の顔の判別や、手書きの文字の読み取りを正確に行うことは難しい。また、予想外の事態への対処や、未知の事柄を類推する能力は有していない。これらの行動は、人間はふだん何気なく行っており、そういった意味で人間の脳はコンピュータとは比べものにならないほどの情報処理機構を持っている。そこで、人間などの生体の脳の神経系の仕組みを工学的に実現し、情報処理を行おうとするニューロンコンピュータが注目されており、ノイマン型コンピュータとは異なる新しいコンピュータの誕生や、現在のコンピュータ技術との融合が期待されている。

(人工)ニューラルネットワークとは、生体の脳で行われている情報処理方式をモデル化したものである。つまり、脳の中での神経細胞によるネットワークの様子を、単純な機能をもつ素子のネットワークとしてモデル化したものである[1]。これにより、生体で行われている学習・汎化などの高度な情報処理を実現できると期待されている。1960年頃にパターン識別装置として提案されたパーセプトロン[2]などで代表される古典的なニューラルネットワークでは、ユニット間でやり取りする情報としてアナログ値を用いている。これらは、証券・金融の分野、航空・宇宙・防衛の分野、ロボット・医療・生産の分野、通信などの分野といった幅広い分野での応用がなされている[3-7]。しかし、生体の脳では、各神経細胞はスパイク(パルス)を用いて情報を表現している[8]。そこで、より生体の脳に近い情報処理機構として、これを模倣したスパイキングニューラルネットワーク[9]は古くからモデル化されてきた[10-14]。しかしながら、古典的なニューラルネットワークに比べ研究の注目度が低かったのは、その仕組みが複雑であるため、大規模なネットワークのコンピュータ上でのシミュレーションが困難であったためである。現在では、コンピュータの性能の向上などにより、コストパフォーマンスの高いコンピュータが容易に入手できることから、スパイキングニューラルネットワークを用いたさまざまな応用が行われるようになってきた[15-18]。

スパイキングニューラルネットワークは従来のシグモイド型のニューラル

ネットワークに比べ、計算力が高いことがいわれている[19-21]。そのため、スパイキングニューラルネットワークでは他のニューラルネットワークに比べ、少ないニューロン数で同じ問題を学習することができる。これは、回路への実装においても、他のニューラルネットワークと同じ複雑性でより高度な計算力を有することができることを意味する。また、スパイキングニューラルネットワークは、ネットワークの情報表現としてスパイクの発火時刻や発火密度を用いており、時間情報を特別なエンコードなしで直接取り扱えるため時系列処理に優れている特徴がある[22]。そのため、音の到達時間を入力信号としそのずれから音源の位置を推定する音源定位[23][24]や、カメラや赤外線センサなどから得られた入力信号により動作を制御する自律ロボット[25-29]などの分野での応用が報告されている。

スパイキングニューラルネットワークには、スパイクの扱い方やネットワーク構造、学習法などの違いにより、さまざまなモデルが存在する。その中で多くの場合、情報表現としてスパイクの発火密度を用いるSTDP(スパイクタイミング依存可搬性)[30-32]と呼ばれるモデルが用いられている。一方、別のモデルとして、情報表現としてスパイクの発火時刻を用いるモデルが存在する。時系列処理を行う際、特にロボット制御といった分野などでは、タイミングの情報が重要である。そのため、スパイクの発火時刻を直接扱えるモデルが必要である。しかし、スパイキングニューラルネットワークに関する研究は、STDPに関する研究が大部分を占めるのが現状である。そこで、本研究では、構成ユニット間での情報表現としてスパイクの発火時刻を用いるSpikeProp[33][34]を研究対象とする。

SpikePropは、積分発火モデルによる複数のニューロンから構成された階層型ニューラルネットワークである。学習則は従来のニューラルネットワークの学習則の一種である誤差逆伝搬法[35]を用いる。SpikePropでは、ユニット間に特殊な結合を用いることで学習を容易にしておき、出力ユニットの発火時刻を学習により調整する。なお、誤差逆伝搬法では勾配を用いた降下法を用いている。一般に勾配を用いた降下法では学習が収束するまでに時間がかかるといった欠点がある[36]。もちろんSpikePropにおいてもこれは例外ではない。そこで、SpikePropでの学習の高速化の研究が行われている[37-41]。特に[39]では、従来のニューラルネットワークにおいて学習の高速化手法であるRProp[42]およびQuickProp[43]をSpikePropに適用し、学習の高速化を試みている。RPropは学習率を適応的に調整するアルゴリズムであり、QuickPropはニューロン法を用いたアルゴリズムである。これらを適用することで学習の高速化に成功してはいるものの、その学習過程には誤差の急激な増加が含まれている。学習過程において誤差が増加すると、再び誤差が減

少する保証はなく、また、誤差が増加する直前で学習が終了すると、ネットワークはわずかなパラメータの変化で出力を大きく変える可能性があり、好ましくない。そのため、学習過程で誤差が増加することを避ける必要がある。

そこで本研究では、SpikePropにおける学習過程の安定性向上を目的とし、学習過程の誤差の振動を抑制する学習法について検討する。

SpikePropの学習過程に誤差の振動が含まれる要因については、Takaseらによって検討されている[44]。SpikePropにおける各ユニットは、複数のシナプスで結合されており、内部電位はスパイク応答関数の重ね合わせとなる。シナプス結合は興奮性・抑制性の二種類あり、抑制性のシナプス結合が内部電位に極大を生じさせる。この極大が発火時刻を不連続に変化させ、誤差に振動を生じさせる。誤差逆伝搬法では一定のステップ幅で探索点を移動するため、このような状況にうまく対応できない。

そこで、本研究では適応的に学習率を調整することで誤差の増加を抑制することを提案する。具体的には、従来の学習法である誤差逆伝搬法に加え、直線探索法を用いることで、適応的に学習率を調整し学習していく。適応的に学習率を調整し、誤差が減少する点を探索することにより、学習過程の誤差の増加を回避できると考えられる。

以下に本論文の構成を示す。2章では本研究で対象としているSpikePropの概要および学習過程における誤差の振動について述べる。3章では誤差の振動を抑制する手法を提案する。4章では提案法の効果について議論し、最後に5章で本研究のまとめをする。

## 第 2 章 SpikeProp

SpikeProp は、積分発火モデルによる複数のニューロンから構成された階層型ニューラルネットワークである。この章では、SpikeProp について、それを構成するスパイクングニューロン、ネットワーク構造、学習法および学習過程における誤差の振動について説明する。

### 2.1 スパイクングニューロン

ニューロンは、多入力-1 出力の非線形素子であり、ひとつの神経細胞をモデル化したものである。ニューロンはこれまでにさまざまなモデルが提案されている。一般に用いられているモデルではニューロンの平均発火率に基づくアナログ値を入出力として用いている。しかし、生体の脳では、ニューロンからニューロンへと信号を伝達する部分であるシナプスには電気パルスが伝達される。そこで、従来のモデルに比べ、より生体の仕組みに近いとして、入出力にスパイク(パルス)を用いるモデルが提案され、これをスパイクングニューロン(以下ユニット)と呼ぶ。

SpikeProp におけるユニットは、積分発火モデルに基づいた動作を行う。ユニットはシナプス前ユニットから発火されたスパイクを受け取り、スパイク応答関数にシナプス強度を乗じた分だけ内部電位が変化していく。内部電位が定められたしきい値に達した瞬間にそのユニットは発火し、次のユニットへとスパイクを出力する。ここで、SpikeProp におけるユニットが他のモデルのユニットと異なる点として、SpikeProp における各ユニットの発火回数は 1 回のみであることである。

SpikeProp におけるユニットの動作例を示す。シナプス前ユニット  $i$  が時刻  $t_i$  にスパイクを出力すると、ユニット  $j$  はユニット  $i$  とユニット  $j$  のシナプス結合に応じた時間遅れ  $d$  だけ遅れてスパイクを受け取る。このとき、シナプス後電位  $y_i$  が生じる。シナプス結合には、興奮性シナプス結合と抑制性シナプス結合があり、興奮性シナプス結合では正である興奮性シナプス後電位が発生し、抑制性シナプス結合では負である抑制性シナプス後電位が発生する。シナプス後電位の関係を式(2.1)に示す。ここでスパイク応答関数  $\varepsilon$  は式(2.2) (図 2.1)で表される。

$$y_i(t) = \begin{cases} \varepsilon(t - t_i - d) & \text{興奮性シナプス結合} \\ -\varepsilon(t - t_i - d) & \text{抑制性シナプス結合} \end{cases} \quad (2.1)$$

$$\varepsilon(t) = \begin{cases} \frac{t}{\tau} e^{1-\frac{t}{\tau}} & (t \geq 0) \\ 0 & (t < 0) \end{cases} \quad (2.2)$$

ここで、 $\tau$ は時定数である。

ユニット $j$ の時刻 $t$ における内部電位 $x_j(t)$ はスパイク応答関数にシナプス結合に応じた結合荷重 $w_{ij}$ を乗じた分だけ変化する。ユニット $j$ へ結合しているシナプス前ユニットの集合を $I_j$ とすると、ユニット $j$ の内部電位 $x_j$ は式(2.3)で表される。

$$x_j(t) = \sum_{i \in I_j} w_{ij} \varepsilon(t - t_i - d) \quad (2.3)$$

内部電位がしきい値 $\theta$ に達したとき、ユニット $j$ はスパイクを出力する。




図 2.1: スパイク応答関数

## 2.2 ネットワーク構造

SpikeProp は, 図 2.2 に示すようにユニット間に特殊な結合をもつ階層型ネットワーク[45]を対象としている. 各ユニットは入力層, 中間層および出力層のいずれかに属し, 単一方向に信号が伝達される. 各ユニット間の結合は  $m$  本の副結合で構成され, 各副結合は調整可能な結合荷重  $w_{ij}^k$  と固定値の時間遅れ  $d^k$  をもつ. ここで,  $w_{ij}^k$ ,  $d^k$  はユニット  $i$  からユニット  $j$  への副結合のうち,  $k$  番目の結合荷重, 時間遅れを表す. 時間遅れは各副結合に対し  $1, 2, 3, \dots, m$  といった一定間隔の整数値を割り当てられ, すべての主結合で同じ値をとる. 時間遅れを固定値とし結合荷重のみを調整可能とすることで, ネットワークの学習を容易にしている. このとき, 式(2.3)で表されたニューロン  $j$  の内部電位  $x_j$  は式(2.4)のように書き改められる.

$$x_j(t) = \sum_{i \in I_j} \sum_{k=1}^m w_{ij}^k \varepsilon(t - t_i - d^k) \quad (2.4)$$






図 2.2: ネットワーク構造

## 2.3 学習法

この節では，Bohte らにより提案された学習法[33]について簡単に説明する．SpikeProp の学習では，出力ユニットの発火時刻を所望の発火時刻に近づけるように，結合荷重を誤差逆伝搬法に基づき変化させる．誤差は，出力ユニット  $j$  の実際の発火時刻  $t_j^a$  と所望の発火時刻  $t_j^d$  を用いて，式(2.5)のように定められている．ここで， $w$  は探索点における結合荷重， $J$  は出力層ユニットの集合である．

$$E(w) = \frac{1}{2} \sum_{j \in J} (t_j^a - t_j^d)^2 \quad (2.5)$$

この  $E(w)$  の探索点における最急降下方向を誤差逆伝搬法により求め，これを用いて式(2.6)に従い結合荷重を繰り返し更新する．ここで， $\eta$  は更新量の比率を定める学習率であり，正の定数である．

$$w \leftarrow w - \eta \frac{\partial E(w)}{\partial w} \quad (2.6)$$

式(2.6)中の勾配  $\frac{\partial E(w)}{\partial w}$  について，中間層-出力層の結合荷重  $w_{ij}^k$  に対する勾配

$\frac{\partial E(w)}{\partial w_{ij}^k}$  および入力層-中間層の結合荷重  $w_{hi}^k$  に対する勾配  $\frac{\partial E(w)}{\partial w_{hi}^k}$  は次のように表される．

出力層-中間層

$$\frac{\partial E(w)}{\partial w_{ij}^k} = y_i^k (t_j^a) \delta_j \quad (2.7)$$

ただし，式(2.7)中の  $\delta_j$  は式(2.8)である

$$\delta_j = \frac{-(t_j^a - t_j^d)}{\sum_{i \in I_j} \sum_{k=1}^m w_{ij}^k \left\{ \frac{\partial \{y_i^k(t)\}}{\partial t} (t_j^a) \right\}} \quad (2.8)$$



入力層-中間層

$$\frac{\partial E(w)}{\partial w_{hi}^k} = y_h^k(t_i^a) \delta_i \quad (2.9)$$

ただし、式(2.9)中の $\delta_i$ は式(2.10)である

$$\delta_i = \frac{\sum_{j \in I^i} \left\{ \delta_j \sum_{k=1}^m w_{ij}^k \left\{ \frac{\partial \{y_i^k(t)\}}{\partial t} (t_j^a) \right\} \right\}}{\sum_{h \in I^i} \sum_{k=1}^m w_{hi}^k \left\{ \frac{\partial \{y_h^k(t)\}}{\partial t} (t_i^a) \right\}} \quad (2.10)$$

## 2.4 学習過程における誤差の振動

前節で説明したように学習を行うことにより、学習の進行に伴い誤差は単調に減少していくはずである。しかし実際の学習過程には、誤差が増加する部分がしばしば発生する。図2.3にその例を示す。これは、**SpikeProp**で時間版XORを学習させたときの学習過程の代表例を示している(詳細な実験条件は、4章の実験に準じる)。学習過程の大部分では学習回数の増加に伴い誤差の値は減少しているが、誤差が振動している箇所が何カ所かあるのがわかる。学習過程では結合荷重は徐々に変化していることから、誤差が増加する前後では、結合荷重のわずかな変化に対してネットワークの出力が急激に変化するといえる。誤差が増加する直前で学習が終了した場合、ネットワークはわずかなパラメータの変化で出力を大きく変える可能性があり、好ましくない。また、誤差が増加した後に、再び誤差が減少する保証もない。そのため、学習過程で誤差が増加することを避ける必要がある。シグモイド型ユニットを用いたニューラルネットワークでもこのような誤差の振動は発生するが、その主な原因は大きすぎる学習率によるものである。そのため、シグモイド型ユニットでは学習率を小さくすれば誤差の増加を回避できる。それに対して、**SpikeProp**では学習率によらず誤差の振動が発生する。

**SpikeProp**の学習過程がこのような振る舞いをする理由について、Takaseらは積分発火ユニットの発火メカニズムに起因するものであり避けることはできないとしている[44]。以下に簡単に説明する。ユニットはスパイク応答関数に結合荷重を乗じた分だけ内部電位を変化させる。スパイク応答関数は連続的な関数であるため、内部電位も連続的に変化することが予想されるが、実際のユニットは、複数のシナプスにより結合されており、内部電位は複数のスパイク応答関数の重ね合わせによって定義される。**SpikeProp**には、内

部電位を減少させる抑制性シナプス結合があり、これより内部電位に極大が生じる。内部電位に極大が生じると、極大をとる時刻から次にその極大を超えるまでの時刻では発火できない。この状態で結合荷重を調整した結果、内部電位の波形はわずかしき変化していないにもかかわらず、極大がしきい値をまたいだため、発火時刻が大きく不連続に変化してしまう(図2.4)。その結果、誤差が不連続に変化し、誤差の振動が生じる。

図2.5に、誤差が増加する直前での最急降下方向での誤差の変化の例を示す。これは、誤差逆伝搬法により求めた最急降下方向のベクトル( $-\nabla E$ )の倍率(ステップ幅:Step width)を横軸とし、それにより結合荷重を更新した後の誤差を縦軸としたものである。これにより、現在の探索点から式(2.6)に従って結合荷重を更新する際のステップ幅と誤差との関係がわかる。この図の時点では、ステップ幅の変化に対して、結合荷重更新後の誤差が不連続に大きく変化していることがわかる。図2.5の状況において、学習率 $\eta$ が0.005より大きいと最急降下方向に結合荷重を更新しているにもかかわらず誤差が増加してしまう。SpikePropにはこのような極小値が多数存在し、固定された学習率で学習する誤差逆伝搬法ではうまく対応できない。そのため、他の学習法の検討が必要である。




図2.3: SpikeProp の学習過程における誤差(時間版 XOR)




図2.4: 出力が不連続となる要因




図 2.5: 誤差増加直前の進み幅と誤差の関係

## 第3章 提案法

誤差逆伝搬法では一定の学習率で学習を行うため、誤差が増加することを避けられない。この章では、適応的に学習率を調整することで誤差の増加を抑制する手法を提案する。本研究では適応的に学習率を調整する手法として最適化のアルゴリズムの1つである直線探索法を用いる。

### 3.1 直線探索法

直線探索法は、最急降下方向において誤差が最小値となるように結合荷重を更新する。探索点  $w_o$  に対し、誤差関数の最急降下方向  $-\nabla E$  の直線上で誤差関数の値が極小になる点に進む。学習における更新式は以下のようになる。

$$\Delta w = -\alpha \nabla E(w_o) \quad (3.1)$$

$$\alpha = \arg \min_{\eta} E(w_o - \eta \nabla E(w_o)) \quad (3.2)$$

$$w \leftarrow w + \Delta w \quad (3.3)$$

ステップ幅を具体的に求めるため、直線探索法では、探索点  $w_o$  より、最急降下方向に沿って極小点を通り越すまで探索点を移動させることで、極小点を含む区間を求め、それを徐々にせばめることで最小点を探し出す。直線探索法では、最急降下方向において誤差が最小となる点を探索するため、これを用いて学習すれば誤差が増加することはない。しかし、極小値が複数存在する場合、最小値以外の極小値で探索が終了し、学習が失敗してしまう可能性がある[36]。SpikeProp では、 $E = E(w)$  で表される学習曲面[45]において極小値が多数存在するため、直線探索法のみで学習した場合、極小解に陥ってしまい学習が失敗してしまうことがしばしば生じる[44]。

### 3.2 誤差逆伝搬法と直線探索法の組み合わせ

2.4節で説明したように、誤差逆伝搬法は一定のステップ幅(学習率 $\eta$ )で探索するため、誤差が不連続に変化する領域においてうまく学習ができない。一方、直線探索法では極小値に陥ってしまうと学習が失敗してしまう可能性がある。そこで、図2.3をみると、学習過程で誤差は振動しているが、学習回数を増やすことで誤差が減少している区間がほとんどである。そこで、誤差が減少する場合は定められた一定の学習率で学習し、誤差が増加した場合のみ、最急降下方向の直線探索法により誤差が減少するような学習率を探索する手法を提案する。これにより、従来の手法を大きく変えることなく、誤差の増加を抑制することができる。全学習過程において適応的に学習率を探索しないのは、次の二つの理由による。第一は、直線探索法では少なからぬ計算量が必要なためである。第二は、SpikePropでは直線探索法により結合荷重を更新すると、局所解に捕らえられやすいためである。

次に、提案法での学習手順を示す。図3.1、3.2および3.3は、探索点における最急降下方向の誤差の曲面を表しており、step ii, step iii, step ivの更新例を示す。ここで、step ivは、直線探索時に局所解に捕らえられた場合の回復策を意図している。

- (i) 初期結合荷重を設定する。
- (ii) 誤差逆伝搬法により結合荷重を更新する(①)。
- (iii) 誤差が増加した場合、直線探索法により誤差が極小値となる点を探索する(②)。
- (iv) 直線探索法で誤差が小さくなる点が探索できなかった場合、手順ii 終了時点に結合荷重を戻す(③)。

学習終了条件を満たすまで、step iiからstep ivを繰り返す。






図3.1: 提案法のアプローチ(step ii)




図3.2: 提案法のアプローチ(step iii)






図3.3: 提案法のアプローチ(step iv)

### 3.3 探索範囲の選択

この節では、提案法における直線探索法の手順について検討し、二つの提案法を示す。多くの直線探索のアルゴリズムでは、誤差の最小点ではなく、探索開始点に最も近い極小点を探し出す。そのため、どの点からどの方向に探索を行うのが重要になる。これをふまえ、二つの手法を提案する。

第一の手法は、step iiの直前の地点からその地点での最急降下方向に直線探索する(step iii A)手法である。以下この手法を、提案法BP+LSと呼ぶ。これは、固定された学習率ではなく、問題が発生する場合には適切な学習率を用いて学習するという、提案法の考え方からすると自然な方法である。ただし、step iiで誤差が増加した場合は、不連続な誤差変化による極小値をこの手順でまたいでいる可能性が高い。そのため、次の結合荷重更新時のstep ii, iiiのいずれも失敗し、誤差の増加を抑制できないことが予想される。そこで、第二の手法を提案する。この手法は、まずstep iiの直後の地点からさきほどの最急降下方向に直線探索(step iii B)し、それで誤差が減少しない場合のみ、step iiの直前の地点から最急降下方向に直線探索する手法である。以下この手法を、提案法BP+2LSと呼ぶ。この手法では、step iiによりまたいだ極小点を避けて、探索を行う。

提案法の探索手順を図3.4に示す。図3.4の黒丸は誤差逆伝搬法による探索点を、矢印は直線探索法の探索範囲を示している。BP+LSではstep iiの直前の地点から直線探索するのに対し、BP+2LSではstep iiの直後の地点から直線探索し、その後step iiの直前の地点から最急降下方向に直線探索する。そのため、BP+LSでは計算量の多い直線探索を2度行うことになるため、計算量の増加が問題となる。

次章でこれらの手法を実験を通じ比較、検討する。

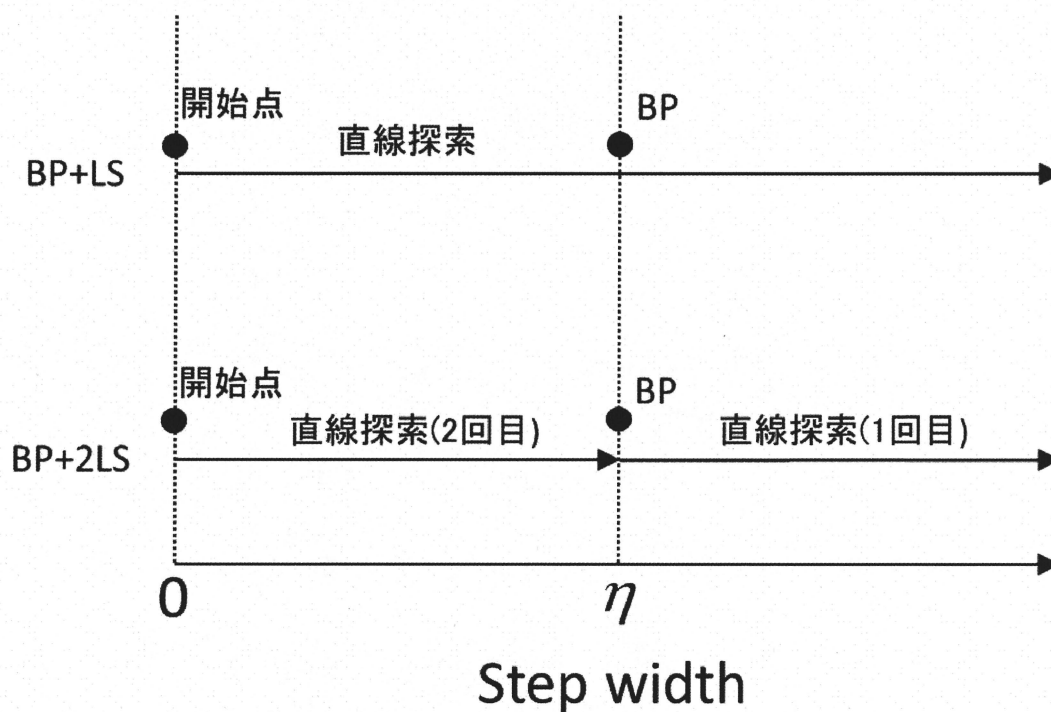


図3.4: 提案法の探索手順

## 第 4 章 実験

本章では，いくつかの実験を通じ，前章で提案した二つの手法のいずれが学習過程における誤差の振動の抑制に対し有効であるのかを検証する．

4.1 節では，実験に用いるデータおよびネットワーク構造の条件について述べる．4.2 節では，実験結果をもとに，二つの提案法どちらが有効であるのかを検討する．

### 4.1 実験条件

実験は Bohte らによる SpikeProp の論文[33]で用いられた条件に準じて行う．実験で用いた SpikeProp のネットワーク構造および各パラメータを表 4.1 に示す．[33]では各ユニットを，すべて興奮性の結合荷重である興奮性ユニットとすべて抑制性の結合荷重である抑制性ユニットに分けている．しかし，興奮性および抑制性の結合荷重を各ユニットに限定した場合，各ユニットが興奮性および抑制性の結合荷重を持つネットワーク構造に比べ汎用性が低くなる恐れがある．そこで本稿の実験では，興奮性および抑制性の結合荷重を各ユニットに限定したネットワーク(IPSP 限定あり)と各ユニットが興奮性および抑制性の結合荷重を持つネットワーク(IPSP 限定なし)の二種のネットワークを対象とする．

学習対象は発火時刻により情報をエンコードした XOR 問題とした．XOR 問題は，線形分離不可能なパターン分類問題であり，ニューラルネットワークの学習について検討する際のベンチマークとしてしばしば用いられる．XOR 問題の入出力関係を表 4.2 に示す．各入力層ユニットへの入力時刻は時刻 0 または 6 のスパイクである．期待する出力は，二つの入力層ユニットへの入力時刻が同一時刻ならば時刻 10 で，そうでなければ時刻 16 でスパイクを出力する．

表4.1: ネットワークの概要

	XOR
入力層ユニット数	3
中間層ユニット数	5
出力層ユニット数	1
主結合 1 本に対する副結合数	16
時間遅れ	1,2,...,16
しきい値	20
時定数	7

表4.2: XOR問題の入出力関係

入力パターン1	入力パターン2	出力パターン
0	0	16
0	6	10
6	0	10
6	6	16

## 4.2 実験結果

SpikeProp の学習法である誤差逆伝搬法に加え直線探索法を組み合わせることで、学習過程における誤差の振動がどの程度抑制されたのか検証する。実験結果は、各手法で XOR 問題の学習を 500 試行した結果のうち、学習に成功した試行の平均を表している。

初めに、提案法の効果を検証するため、誤差逆伝搬法のみ(従来法)および提案法における誤差が増加する割合について表 4.3, 4.4 に示す。表 4.3 では学習終了条件の許容誤差を 0.01 に、表 4.4 については 1.00 とした。表中の増加割合は、各試行での学習回数(結合荷重の更新回数)に占める、誤差が増加した更新回数の平均したものである。

表 4.3 における誤差の増加割合について、IPSP ありでは従来法に比べ提案法はともに減少していることがわかる。これらは  $t$  検定を行った結果、ともに有意差( $p < 0.01$ )が確認できた。このことから、IPSP ありでは提案法により誤差の増加を回避することができたといえる。また、BP+LS と BP+2LS を比べると、BP+2LS の方が増加割合は有意( $p < 0.01$ )に低かった。一方、IPSP なしでは、従来法に比べ提案法の方が有意差( $p < 0.01$ )で増加割合が高くなった。この理由としては、IPSP なしは IPSP ありに比べ局所解が多く存在するためだと考えられる。提案法において直線探索法でこれらの局所解に陥ってしまった場合、次の結合荷重の更新時に誤差逆伝搬法および直線探索法ともに失敗し、誤差が増加する可能性が高い。また、その次の更新時においても再び局所解に陥る可能性があり、極小値付近での学習が繰り返され、誤差の振動が引き起こされる可能性が高い。そのため、誤差の増加が何度も繰り返されてしまい増加割合が高くなったと考えられる。

次に表 4.4 をみると、IPSP ありおよび IPSP なしともに提案法の方が増加割合が低くなった。 $t$  検定を行った結果、有意水準  $p < 0.01$  において IPSP ありでは BP+LS, BP+2LS とともに有意差あり、IPSP なしでは BP+LS では有意差なし、BP+2LS では有意差ありという結果となった。

表 4.3 の結果に比べ表 4.4 の方が提案法の効果が高くなっている。これは次のような理由が考えられる。学習序盤では、興奮性の結合荷重の方が抑制性の結合荷重より割合が高いため、内部電位に極大・極小が生じにくく、発火時刻は連続的に変化しやすい。しかし、学習が進むにつれて、抑制性の結合荷重の割合が高くなっていき、その結果、内部電位に極大・極小が生じ、発火時刻が不連続に変化する。これにより、誤差は不連続に変化し、局所解が発生すると考えられる。

表 4.3: 各手法による誤差の増加割合(誤差基準:0.01)

手法	IPSP	学習回数	増加割合
BP	あり	201.6	20.0
BP+LS		190.4	16.9
BP+2LS		183.4	14.9
BP	なし	197.5	11.3
BP+LS		242.8	20.0
BP+2LS		237.9	19.1

表 4.4: 各手法による誤差の増加割合(誤差基準:1.00)

手法	IPSP	学習回数	増加割合
BP	あり	146.0	17.8
BP+LS		131.8	12.9
BP+2LS		128.4	11.4
BP	なし	110.5	12.5
BP+LS		96.4	11.0
BP+2LS		98.7	9.4

そこで、極小値が誤差の値に対してどのような分布をとるのか調査した。今回は、提案法で誤差が増加した際の誤差の値の範囲を調査する。これは、提案法で誤差が増加する現象は、前回の学習での探索点が極小値に陥ったときのみにもみられるためである。実験結果を図 4.1, 4.2 に示す。横軸は誤差が増加した際の誤差の値の範囲を、縦軸は 500 試行中の学習が成功したパターンのうち誤差が増加した総数を表す。ただし、許容誤差は 0.01 である。

図 4.1, 4.2 から、誤差の値の範囲が 0 から 1 の範囲において極小値に陥る回数が IPSP ありでは全体の約 40%, IPSP なしでは約 50%を占めており、誤差の増加回数が増加していることがわかる。そのため、提案法では学習の終了条件を厳しく設定すると誤差の振動の抑制の効果が薄くなるといえる。

ここで学習終了条件について考える。XOR 問題では望ましい出力時刻は 10 または 16 であるため、この二者を区別するための時刻のしきい値は 13 である。すべてのパターンに対して 13 を出力する場合の誤差は 18 であり、学習終了条件が 0.01 以下というのは過剰な設定であるといえる。また、学習終了条件を厳しく設定すると過学習につながる恐れもあり、このことから、提案法を適用する場合は、学習終了条件を適度に設定するのが好ましいといえる。






図 4.1 : 誤差の値の範囲と誤差の増加回数(IPSP あり)




図 4.2 : 誤差の値の範囲と誤差の増加回数(IPSP なし)



次に、二つの提案法の比較を行うため、提案法における各ステップ(3.3 節参照)の割合を調査した。実験結果を表 4.5,4.6 に示す。表内の各数値は全体の学習回数に対する各ステップの割合を示す。step iii A は誤差逆伝搬法で誤差が増加した地点( $\eta=1.0$ )からの探索, step iii B は誤差が増加する際に一度探索点を戻した地点( $\eta=0$ )からの探索である。各表ともに step iii B はわずかしかな実行されていないことがわかる。このことから、誤差が不連続に変化する領域では、誤差が増加する点より大きな学習率で学習を行っても誤差が減少する点はほとんどみつからないといえる。

表 4.3, 4.4 では、BP+2LS の方が増加割合は低い結果となったが、ステップ iii B は 1%程度しか実行されず、計算量を考慮すると BP+LS の方が有効であると考えられる。

表 4.5: 各手法によるステップ別の割合(誤差基準:0.01)

手法	IPSP	Step ii	Step iii A	Step iii B	Step iv
BP	あり	1.00	—	—	—
BP+LS		0.58	0.25	—	0.17
BP+2LS		0.59	0.25	0.01	0.15
BP	なし	1.00	—	—	—
BP+LS		0.48	0.32	—	0.20
BP+2LS		0.45	0.35	0.01	0.19

表 4.6: 各手法によるステップ別の割合(誤差基準:1.00)

手法	IPSP	Step ii	Step iii A	Step iii B	Step iv
BP	あり	1.00	—	—	—
BP+LS		0.68	0.19	—	0.13
BP+2LS		0.67	0.21	0.01	0.11
BP	なし	1.00	—	—	—
BP+LS		0.62	0.27	—	0.11
BP+2LS		0.62	0.28	0.01	0.09

最後に、提案法を適用した際の学習過程の図を図 4.3, 4.4 に示す。これらは図 2.3 と同じ初期荷重から学習した際の学習過程である。各図とも学習過程で誤差の増加はほとんどなく、提案法により学習過程が安定になったことがわかる。




図 4.3: BP+LS による XOR 問題の学習過程




図 4.4: BP+2LS による XOR 問題の学習過程

## 4.2 実験のまとめ

これまでの実験により，SpikeProp に提案法を適用することにより，学習過程の誤差の増加を回避することができ，学習過程が安定することが示された．許容誤差の値が小さい場合，提案法の効果は薄くなる性質があるが，学習終了条件を厳しく設定すると過学習につながる恐れもあり，SpikeProp を用いる際には許容誤差の値は小さく設定することは必要なく，これは深刻な問題ではないと考えられる．

一方で，BP+LS と BP+2LS を比べると，当初では BP+2LS の方が効果は高いと予想していたが，実験結果からは二つの提案法での誤差の増加割合に大きな差は見いだせなかった．これは表 4.5, 4.6 をみてもわかるとおり，Step iii B は全体の学習回数に対してわずか 1%程度にすぎなかったためである．そのため，BP+2LS は計算量の増加を招くだけという結果となった．

以上の結果から，誤差の増加割合および計算量を考慮した場合，BP+LS が最も効果的な学習法であるといえる．

## 第5章 まとめ

本研究では、SpikeProp における学習過程の安定性向上を目的とし、学習過程の誤差の振動を抑制する学習法を提案した。

SpiekPropでは、従来のシグモイド型ニューラルネットワークには存在しない要因で誤差が不連続に変化してしまう。これはSpikePropの発火メカニズムに起因するものであり、従来の学習法のみだけでは避けることができなかった。そこで、従来の学習法である誤差逆伝搬法に加え直線探索法を組み合わせた手法を提案した。誤差逆伝搬法と直線探索法を組み合わせたのは次の理由のためである。第一は、直線探索法では少なからぬ計算量が必要なためである。第二は、SpikePropでは直線探索法により結合荷重を更新すると、局所解に捕らえられやすいため、直線探索法のみでは学習が失敗する確率が高くなるからである。提案法を適用した結果、誤差の振動を抑制することができた。しかし、一度局所解に陥ると、極小値付近で学習が反復され、学習回数の増加を招く場合があることがわかった。ただし、このような局所解は誤差の値が小さいときに多くみられる現象であり、学習終了条件の誤差基準を適切に設定すれば、学習回数の増加を防ぐことができた。

今後の課題としては、局所解に陥ってしまった際の解決策を考案する必要がある。局所解に陥った場合、最急降下方向に結合荷重を更新しても誤差の増加は回避できないため、何らかの工夫が必要である。

# 謝辞

本論文は，著者が三重大学大学院工学研究科博士前期課程時に行った研究をまとめたものである．本論文を進めるにあたり，懇切丁寧な御指導と御督励を賜った三重大学の鶴岡信治教授，高瀬治彦准教授，川中普晴助教，内藤克浩助教に深く感謝いたします．また，日頃熱心に討論していただいた情報処理研究室の皆様方に厚く御礼申し上げます．

最後に，本論文をまとめるにあたり，助言，討論，その他お世話になったすべての方々に感謝いたします．

## 参考文献

- [1] 臼井支郎, 岩田彰, 久間和生, 浅川和雄: 基礎と実践 ニューラルネットワーク, コロナ社, (1995)
- [2] F. Rosenblatt: The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain, Psychological Review, Vol.65, pp.386-408, (1958)
- [3] T. J. Sejnowski, and C. R. Rosenberg: Parallel networks that learn to pronounce English text, Complex Systems, Vo.1, pp.145-168, (1987)
- [4] T. Yamashita, K. Hirasawa, H. Jinglu: Appcication of multi-branch neural networks to stock market prediction, Proceedings of International Joint Conference on Neural Networks 2005, pp. 2544-2548, (2005)
- [5] K. Watanabe, J. Tang, M. Nakamura, S. Koga, T. Fukuda: A fuzzy-Gaussian neural network and its application to mobile robot control, IEEE Transactions on Control Systems Technology, Vol.4, Issue2, pp.193-199, (1996)
- [6] 菊池豊彦: 入門 ニューロコンピュータ, オーム社出版局, (1990)
- [7] 武藤佳恭, 斉藤孝之: 応用事例ハンドブックニューラルコンピューティング, 共立出版株式会社, (2001)
- [8] 銅谷賢治, 伊藤浩之, 藤井宏, 塚田稔: 脳の情報表現—ニューロン・ネットワーク・数理モデル, 朝倉書店, (2002)
- [9] W. Mass, and Christopher M. Bishop: Pulsed Neural Networks, The MIT Press, pp.3-85, (1999)

- [10] W. S. McCulloch, and W. H. Pitts: A logical calculus of the Ideas immanent in nervous activity, Bulletin of Methemathical Biophysics, Vol.5, pp.115-133, (1943)
- [11] A. L. Hodgkin, and A. F. Huxley: A quantitative description of membrane currents and its application to conduction and excitation in nerve, Journal of Physiology, Vol.117, pp. 500-544, (1952)
- [12] R. FitzHugh: Impulses and physiological states in theoretical models of nerve membrane, Biophysical Journal, Vol. 1, pp. 445-466, (1961)
- [13] K. Aihara, T. Takabe, and M. Toyoda: Chaotic Neural Networks, Physics Letters A, Vol.144, Issues6-7, pp.333-340, (1990)
- [14] N. Schweighofer, K. Doya, and M. Kawato: Electrophysiological properties of inferior olive neurons: A compartmental model. Journal of Neurophysiology, Vol. 82, pp. 804-817, (1999)
- [15] F. Alnajjar, K. Murase: Sensor-fusion in spiking neural network that generates autonomous behavior in real mobile robot, Proceedings of International Joint Conference on Neural Networks 2008, pp. 2200-2206, (2008)
- [16] Eugene M. Izhikevich: Solving the Distal Reward Problem through Linkage of STDP and Dopamine Signaling, Cerebral Cortex Vol.17, pp.2443-2452, (2007)
- [17] 川人光男: 小脳内部モデルとモザイクの計算的神経科学, 人工知能学会誌, Vol.17, No.6, pp.720-731, (2002)
- [18] W. Gerstner, and J. L. van Hemmen: How to describe neural activities: Spikes, rates of assemblies?, Advances in Neural Information Processing Systems, Vol.6, pp.363-374, (1993)

- [19] W. Maass: Noisy spiking neurons with temporal coding have more computational power than sigmoidal neurons, *Advances in Neural Information Processing System 9*, Vol.9, pp.211-217, (1997)
- [20] W. Maass: Lower bounds for the computational power of networks of spiking neurons, *Neural Computation*, Vol.8, No.1, pp.1-40, (1996)
- [21] W. Maass: Networks of spiking neurons: the third generation of neural network models, *Neural Networks*, Vol.10, No.9, pp.1659-1671, (1997)
- [22] 瀧田航一郎: パルスニューラルネットワークによる時系列情報処理に関する研究, 慶應義塾大学博士論文, (2005)
- [23] 黒柳奨, 奥村享司, 岩田彰: パルスニューロンモデルを用いた音源定位聴覚系モデル-位相情報抽出のためのニューロン層の構築-, 電子情報通信学会技術研究報告, Vol.96, No.134, pp.163-169, (1997)
- [24] W. Gerstner, R. Kempter, J. Leo van Hemmen, and H. Wagner: Hebbian Learning of Pulse Timing in the Barn Owl Auditory System, In W. Maass, and M. C. Bioshop, editors, *Pulsed Neural Networks*, The MIT Press, Cambridge, Massachusetts, pp.353-377, (1998)
- [25] 元木誠, 小坂成一, 平田廣則: ニューラルネットワークの違いに着目した自律移動ロボットコントローラの性能比較, 電子情報通信学会技術研究報告, Vol.105, No.457, pp.25-30, (2005)
- [26] H. Hagnas, Anthony Pounds-Cornish, Martin Colley, Victor Callaghan and Graham Clarke: Evolving Spiking Neural Network Controllers for Autonomous Robots, *Proceeding of the 2004 IEEE International Conference on Robotics and Automation*, pp.4620-4626, (2004)
- [27] Xiuqing Wang, Zeng-Guang Hou, Anmin Zou, Min Tan, Long Cheng: A behavior Controller based on spiking neural networks for mobile robots, *Neurocomputing* 71, pp.655-666, (2008)



- [28] D. Floreano, and C. Mattiussi: Evolution of Spiking Neural Controllers for Autonomous Vision-Based Robots, Proceeding of the International Symposium on Ebolutionary robotics, pp.38-61, (2001)
- [29] D. Floreano, N. Schoeni, G. Caprari, J. Blynel: Evolutionary Bits'n'spikes, Proceedings of the Eighth International Conference on Artifical Life, pp,335-344, (2002)
- [30] Guo-qiang Bi, Mu-ming Poo: Synaptic Modifications in Cultured Hippocampal Neurons: Dependence on Spike Timing, Synaptic Strength, and Postsynaptic Cell Type, The Journal of Neuroscience, 18(24), pp.10464-10472, (1998)
- [31] PJ. Sjostrom, GG. Turrigiano, and SB Nelson: Rate, timing, cooperativity jointly determine cortical synaptic plasticity, Neuron, 32, pp.1149-1164, (2001)
- [32] H. Markram, J. Lubke, M. Frotscher, and B. Sakmann: Regulation of Synaptic Efficacy by Coincidence of Postsynaptic Aps and EPSPs, Sience, Vol.275, pp.213-215, (1997)
- [33] S. M. Bohte, H. L. Poutre, and J. N. Kok: Error-Backpropagation in Temporally Encoded Networks of Spiking Neurons, Neurocomputing, Vol.48, pp.17-37, (2002)
- [34] Simon Christian Moore: Back-propagation in Spiking Neural Networks, Master's thesis, University of Bath, (2002)
- [35] 吉富康成: シリーズ非線形科学入門 ニューラルネットワーク, 朝倉出版, pp.27-49, (2002)
- [36] 金谷健一: これなら分かる最適化数学ー基礎原理から計算手法まで, 居率出版, (2005)

- [37] Benjamin Schrauwen, and Jan Van Campenhout: Extending Spike Prop, Proceedings of the 15th ProRISC Workshop, pp.301-305, (2004)
- [38] Sergio M. Silva, Antonio E. Ruano: Application of the Levenberg-Marquardt method to the training of Spiking neural networks, Proceedings of 2006 International Joint Conference on Neural Networks, pp.7709-7713, (2006)
- [39] S. McKennoch, D. Liu, and L. G. Bushnell: Fast Modifications of the SpikeProp Algorithm, Proc. of 2006 International Joint Conference on Neural Networks, pp.7701-7708, (2006).
- [40] Benjamin Schrauwen, and Jan Van Campenhout: Improving Spike Prop: Enhancements to An Error-Backpropagation Rule for Spiking Neural Networks, Proceedings of the 15<sup>th</sup> ProRISC Workshop, (2004)
- [41] J. Xin, and M. Embrechts: Supervised learning with spiking neural networks, Proceedings of International Joint Conference on Neural Networks, pp.1772-1777, (2001)
- [42] M. Reidmiller, and H. Braun: A direct adaptive method for faster backpropagation learning: The RPROP algorithm, IEEE International Conference on Neural Networks, Vol.1, pp.586-591, (1993)
- [43] S. E. Fahlman: An Empirical Study of Learning Speed in Back-Propagation Network, Technical Report CMU-CS-88-162, Carnegie-Mellon University, School of Computer Science, (1998)
- [44] H. Takase, M. Fujita, H. Kawanaka, S. Tsuruoka, H. Kita, and T. Hayashi: Obstacle to Training SpikeProp Networks – Cause of Surges in Training Process –, Proceedings of International Joint Conference on Neural Networks 2009, pp.3062-3066, (2009)
- [45] T. Natschlager, B. Ruf: Spatial and Temporal Pattern Analysis via Spiking Neurons, Network Computation in Neural Systems Vol.9, No.3, pp.319-332, (1998)

- [46] 奥田利信, 郷原一寿, 内川嘉樹: 線形3層ニューラルネットワークにおける記憶面および学習曲面の解析, 電子情報通信学会論文誌, Vol.J76-D-2, No.7, pp.1441-1448, (1993)

## 発表論文

- [1] 若松俊希, 高瀬治彦, 川中普晴, 鶴岡信治: SpikeProp における学習過程の誤差の振動を抑制する手法 –探索点の決定法–, 第30回東海フエジィ研究会講演論文集, pp.2-1-2-4, (2011)
- [2] WAKAMATSU Toshiki, TAKASE Haruhiko, KAWANAKA Hiroharu, and TSURUOKA Shinji: A Training Algorithm for SpikeProp Improving Stability of Learning Process, 2011 International Joint Conference on Neural Networks San Jose, California, pp.951-955, (2011)
- [3] Toshiki Wakamatwsu, Haruhiko Takase, Hiroharu Kawanaka, and Shinji Tsuruoka: Improve Stability of Learning Process by SpikeProp –Combination Error-Backpropagation and Linear Search–, International Symposium for Sustainability by Engineering at MIU, pp.331-335, (2011)