

乗算器が不要なパルスニューロンモデルの実数値入出力

本木 実* 細井 勇佑**
松尾 和典***

Real Value Input and Output of Pulsed Neuron Model without Multiplier

MOTOKI Minoru*, HOSOI Yusuke**, MATSUO Kazunori***

This paper describes an experimental result of a pulsed neuron model without multiplier for digital circuit. Iwata et al. proposed a pulsed neuron model for digital circuit, and succeeded in decreasing circuit scale without using multiplier in execution process. However, a multiplier is used in learning process and some circuit scale was required. Hosoi et al. proposed a learning rule of the pulsed neuron model without multiplier in learning process. And we report performances of the proposed method for real value input and output by a computer simulation.

キーワード：パルスニューロンモデル，乗算器，デジタル回路，FPGA，ASIC，パターン認識，関数近似
Keywords: pulsed neuron model, multiplier, digital circuit, FPGA, ASIC, pattern recognition, regression

1. はじめに

本稿では、階層型ニューラルネットをデジタル回路で実現するための乗算器が不要なパルスニューロンモデルとその実験について述べる。

ニューラルネットは、ロボット制御やパターン認識、データ予測を始め、様々な分野に応用されている。ニューラルネットを電子製品へ搭載し、シングルプロセッサで処理する場合は、結局、ソフトウェアで処理することになり、並列処理が順次処理に置き換えられる。すると、並列性というニューラルネットの利点を活かす事ができないだけでなく、応答時間に対し問題が生じる場合がある。そのため、高速化のためにはハードウェア化を行う必要がある。

ニューラルネットのハードウェア化には、アナログ方式、デジタル方式、パルス密度変調方式、パルス幅・位相変調方式、ミックスト・シグナル方式など様々な方式が考えら

れている⁽¹⁾。岩田らは、パルス密度変調方式の1つであるパルスニューロンモデル(PNモデル)を、階層型ニューラルネットの1つとして提案した⁽²⁾。このモデルでは、デジタル方式では多数のバス幅と乗算器が必要であったのに対し、入力信号が0または1の1ビットで表現されるため、入力、出力、ニューロン間結合が1ビットで済む。さらに、入力値と結合重みの乗算もAND回路もしくはマルチプレクサに置き換えることができる。しかし、岩田らのPNモデルは実行過程には乗算器を必要としないが学習過程には乗算器が必要なため、ある程度の回路規模が必要であった。そこで細井ら(我々)は、学習時にも乗算が不要なモデルを提案した⁽³⁾。一般的に、乗算器の占める回路規模はデジタルデバイスにおいて非常に大きいので、乗算器が不要なニューロンモデルの提案は、ニューラルネットの大規模集積化への1つの貢献となると考えられる。さらに我々は、シミュレーションによって、パターン認識動作をバイナリ値入出力(実際にはXOR問題)により確認した。

さて、階層型ニューラルネットの機能は、パターン認識(判別問題とも言う)、関数近似(回帰問題とも言う)が主である。関数近似は任意の実数値の入出力関係を表現することになるため、関数近似ができればパターン認識も可能である。例えば、強力なパターン認識器の1つであるサポートベクトルマシン(SVM)は関数近似には向かないという認識もあるが、ニューラルネットは関数近似が可能である。

我々は、提案モデルをパターン認識(バイナリ値の入出力)については実験によって確かめたが、関数近似(実数値の入出力)については、確認していなかった。そこで本稿

* 情報通信エレクトロニクス工学科
〒861-1102 熊本県合志市須屋 2659-2
Department of Information, Communication and Electronic Engineering
2659-2, Suya, Koshi, Kumamoto 861-1102
** 専攻科 電子情報システム工学専攻
〒861-1102 熊本県合志市須屋 2659-2
Advanced Course of Electronics and Information Systems Engineering
2659-2, Suya, Koshi, Kumamoto 861-1102
*** 制御情報システム工学科
〒861-1102 熊本県合志市須屋 2659-2
Department of Control and Information Systems Engineering
2659-2, Suya, Koshi, Kumamoto 861-1102

では, 提案モデルの関数近似機能の確認へ向けての1つの実験として, 実数値の入出力の実験を行ったので報告する.

2. パルスニューロンモデル

2.1 マッカロ-ピッツモデル

ニューロンのモデルとして有名なものに1943年のマッカロ-ピッツ (McCulloch-Pitts) のモデル (MP モデル) がある (図1). このモデルでは, i_n がアナログ入力, w_n が結合重み, θ がニューロンの発火閾値である. これらを式で表すと,

$$y = f(u) \dots \dots \dots (1)$$

$$u = \sum_{i=1}^n w_i x_i - \theta \dots \dots \dots (2)$$

$$f(u) = \begin{cases} 1 & (u \geq 0) \\ 0 & (u < 0) \end{cases} \dots \dots \dots (3)$$

となる. しかし, このMPモデルは入力・結合重みともに実数値である. すなわち $x_i \in \mathbf{R}, w_i \in \mathbf{R}$ である. 実数値はデジタルニューロデバイスのハードウェア上では一定のビット長をもった固定小数点表現などのデジタル値に置き換えられて演算が行われる. 多ビット同士の乗算を行うためには回路規模の増大は避けられない. そのためMPモデルはデジタル回路のハードウェア化には不向きである.




図1 McCulloch-Pitts のモデル

2.2 岩田らのモデル

次に, 岩田らが提案するPNモデル⁽²⁾を考察する. PNモデルとは, 単一神経細胞の電気的活動を模倣したモデルであり, 入力信号, 出力信号ともパルス列 (バイナリ値) である. すなわち, $i_n \in \mathbf{B}, O(t) \in \mathbf{B}, \mathbf{B} = \{0, 1\}$ である. 図2にPNモデルを示す. PNモデルにおいてはそれぞれの信号の大きさはパルス頻度として表される. 例えばMPモデルで入力値が0.5であったとすると, PNモデルでは入力値の発火確率が0.5となる. 発火確率が0.5では100回のうちおよそ50回発火する. そして, 膜電位というパラメータを持つ. 膜電位は入力に対する局所膜電位 $p_n(t)$, 入力頻度膜電位 $pi_n(t)$, 出力膜電位 $po(t)$, 教師信号膜電位 $pt(t)$ が存在する. PNモデルの処理過程は以下の通りである.




図2 岩田らのPNモデル

- (1) 各膜電位は減衰を行う. 減衰の時定数を τ とすると, $p(t) = e^{-\frac{t}{\tau}} \cdot p(t-1)$ で減衰する. (4)
- (2) 各シナプスにて入力パルスが1であるならば結合重み分だけ局所膜電位が上昇する.
- (3) PNの総膜電位 $I(t)$ は局所膜電位 $p_i(t)$ の総和となる.

$$I(t) = \sum_{i=1}^n p_i(t) \dots \dots \dots (5)$$

- (4) 総膜電位が閾値を超えたとき発火する.

$$O(t) = f(I(t)) = \begin{cases} 1 & (I(t) \geq 0) \\ 0 & (I(t) < 0) \end{cases} \dots (6)$$

学習手法は, 教師あり学習として有用な誤差逆伝播法に関連した手法が用いられている. PNモデルが2層で構成される場合, 誤差逆伝播法に準じる手法にて学習を行うことができることが確認されている⁽²⁾. しかし, 中間層を有する場合, 中間層への誤差信号を計算することができない. これは誤差逆伝播法では出力関数が微分可能な関数である必要があるが, PNモデルでは(6)式のように微分不可能な関数を用いているため誤差逆伝播法は適用できない. そのため, 誤差逆伝播法を使用せず, ニューラルネットの持つ双対性を利用して中間層への教師信号を作成する方法で学習を行う⁽⁴⁾. PNモデルでは最小単位時間ごとに重みの更新を行う. 重みの更新式は

$$w_n(t+1) = w_n(t) + \alpha(po(t) - pi_n(t)) \dots (7)$$

となる. なお α は学習係数である. 中間層の教師信号 $T^h(t)$ を作成する. これは, 入力と重みの双対性を利用して求められる. まず中間層の教師信号の変化分 $\Delta T^h(t)$ を

$$\Delta T^h(t) = \alpha \sum_{k=1}^K (T_k^O(t) - O_k(t)) w_k^O(t) \dots \dots \dots (8)$$

として求める. $T_k^O(t)$ は出力層の教師信号, $O_k(t)$ は出力信号であり0または1のパルス列である. そして, ニューロンの出力値が1か0のバイナリ値であるPNモデルでは, 学習閾値 θ_{learn} を設定し次の法則によって教師信号を決定する.

- (a) $\Delta T^h(t) > \theta_{learn}$ の場合, $T^h(t) = 1$ とする.
- (b) $\Delta T^h(t) < -\theta_{learn}$ の場合, $T^h(t) = 0$ とする.
- (c) $|\Delta T^h(t)| \leq \theta_{learn}$ の場合, $T^h(t) = H(t)$ とする. 但し $H(t)$ は中間層の出力.

以上のようにして中間層への教師信号を作成し, 教師あり学習を行う. その結果, 線形分離不可能な入力パターンの認識を行うことが可能となる.

2.3 提案モデル

岩田らが提案した PN モデル⁽²⁾⁽⁴⁾ は, 実行過程においては乗算器を用いずに回路規模を抑えて実現されている. しかし, 学習過程においては乗算器が用いられているので, ある程度の回路規模が必要とされていた. そこで我々はハードウェア化に際して乗算器が不要なパルスニューロンモデルの学習手法の考案を行った.

岩田らのモデルにおいては膜電位というパラメータが存在する. 各膜電位の入力パルスに対する膜電位上昇量は, 局所膜電位 $p_n(t)$ に関しては結合重み w_n 分であり, その他の入力頻度膜電位 $pi_n(t)$, 出力膜電位 $po(t)$, 教師膜電位 $pt(t)$ に対しては定数 α 分である. そして, 減衰があるため膜電位の値はある程度の値以上に保たれることが予想される. 膜電位 $pi_n(t)$ の値こそが MP モデルでの入力値 x に相当するものではないかと考えられる.

PN モデルの結合重みの更新式は (7) 式で与えられる. この更新式の主要部は $(pt(t) - po(t))(\in \mathbf{R})$ という教師信号の大きさと出力信号の大きさの差によって重みの更新量が決まる. さらに, $(pt(t) - po(t))pi_n(t)$ により入力頻度 $pi_n(t)(\in \mathbf{R})$ の値によっても更新量が変化する. つまり, 教師信号と出力信号の差が大きいと重みは大きく更新され, 逆に小さいのであれば小さく更新される. それとともに, 入力が多くあれば大きく更新し, 入力が少ないのであれば小さく更新される. これらが膜電位を用いて学習を行うことの利点である. しかし, 膜電位を利用することの欠点として学習の過程において $(pt(t) - po(t))pi_n(t)$ があるため実数値と実数値の乗算が必要となる.

まとめると, 学習を行うことは重みの更新することと同義である. 重みを更新することは

- 重みの値を増加させる
- 重みの値を減少させる
- 重みは正しい値であり更新をしない

のいずれかである. そこで, 提案手法では重みの更新式を

$$w_n(t+1) = w_n(t) + \alpha(T(t) - O(t))i_n(t) \dots \dots (9)$$

としている. 膜電位による更新量の制御を行わず更新量を定数とし, 学習回数を増やすことと最適な学習係数を定めることで学習を可能にする. $(T(t) - O(t))$ で重みを増加させるか減少させるか更新を行わないかを決定し, $i_n(t)$ により入力があれば更新, なければ更新しないとといった判断をする. 更新量は学習係数 α に依存する.

以上のように, 提案手法では学習時にも実数値 α とバイナリ値 (0 か 1) の乗算になるため AND 回路またはマルチ

プレクサに置き換えることができ回路規模の縮小化が可能となる.

提案手法では, 膜電位による更新量の制御を行わず更新量を定数としたが, 本稿の目的である実数値の入出力を実現するためには, 一時的に入力値を保持しておく機構が必要である. そのため, 膜電位と同様な機構をとりいれている. 但し, 岩田らの PN モデルで行っている膜電位の減衰は行わず[†], 単位時間で 0 にリセットする. 提案した PN モデルを図 3 に示す.




図 3 提案モデル

実行過程は岩田らの PN モデルと同様に (5)(6) 式に準じている.

3. シミュレーション

提案手法を用いて学習シミュレーションを行った. シミュレーションには C 言語 (gcc) を用いてソフトウェア上にて行った. タスクは表 1 のような排他的論理和 (XOR) を取り扱う. このタスクは関数近似ではなくパターン認識になるが, まずは, パターン認識ではあるがバイナリ値でない (実数値の) 入出力関係を表現できるかを確認した. ニューラルネットの構成は, 入力ユニット 2 個, 中間ユニット 2~5 個, 出力ユニット 1 個の 3 層からなるネットワークとした.

表 1 実数値入出力のタスク

入力信号		教師信号
0.0	0.0	0.0
0.0	0.2	0.6
0.2	0.0	0.6
0.2	0.2	0.0

学習は学習係数 α による影響を調査した. 学習係数の値は $10^{-6} \sim 10^{-4}$ の間で変化させ, 重みの初期値は $[0.1, -0.1]$ の一様乱数 100 系列を用いた. 学習を行うに当たって学習成功率を設定する. 学習成功率は 100 系列の重みのうち, 学習が成功した回数を表したものであり. 今回は, 教師信号と出力との誤差 E が 0 となったときに学習が成功したとみなす. 誤差はパルス頻度の平均誤差を用いる. 出力ユニットの数を K 個, 学習パターン数を N 個とし, 出力信号, 教師信号の発火確率を $freq(O), freq(T)$ とおくと,

[†]これは, 生体のニューロンモデルとかけ離れたものとなるが工学的に機能を実現出来れば良いと考え問題視はしていない.




図 4 実数値入出力の学習結果




図 5 バイナリ値入出力の学習結果

$$E = \frac{1}{NK} \sum_{p=1}^N \sum_{k=1}^K |freq(T_{k,p}) - freq(O_{k,p})| \quad (10)$$

となる。ただし、発火確率を求める $freq()$ は、単位時間は 100clock (100clock 間で 1 つの情報を表す) とし、出力 y の発火確率

$$freq(y) = \frac{1}{100} \sum_{t=1}^{100} y(t) \dots\dots\dots (11)$$

を計算した。単位時間 100clock で学習回数を 1 回とした。

図 4 に学習成功率を示す。学習成功回数は 0 ではないので、学習が全く成功しないわけではないが、非常に成功しにくいことがわかった。参考のために、図 5 に入出力値を 1,0 のバイナリ値とした (通常の XOR 問題の) タスクの結果を示す。これと比較して、今回の実数値入出力は、バイナリ値入出力に比べ、学習の収束が難しいことがわかる。

なお、入力の膜電位 (値保持機構) なしでは全く学習は成功しなかった。

4. 考 察

提案手法では、原理的に任意の実数値の出力を創り出すことが難しい。これは、先に述べた通り提案モデルでは出力側に一時的に値を保持しておく機構がないためである。例えば、出力を y , 入力を x として関数 $y = \frac{1}{2}x$ の学習を

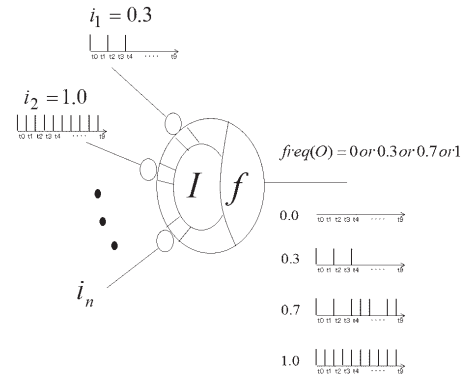


図 6 入力に対する表現可能な出力 (提案モデル)

行うとする。すると、入力の発火確率が 1 だとすると、出力の発火確率は 1 か 0 しか出力できない。また、入力の発火確率が 0.3 だとすると、出力の発火確率は 0, 0.3, 0.7, 1 のいずれかは作り出せるが、他の値を作り出すことは原理的に不可能である。(図 6)。そして、0 または 1 が出力されている場合は、入力の 0.3 に依存していない。このように、出力値が入力値のバリエーションに依存してしまうため、出力関数をシグモイド関数とするニューロンモデルなどと異なり、任意の値を出力することができない。このことから、関数近似を行うためには単位時間毎に中間値を作成することや出力関数を工夫する必要があると考えられる。

5. おわりに

本稿では、岩田らの学習手法を変更し、乗算器の不要な PN モデルの学習手法とその実数値入出力に関するシミュレーションについて述べた。提案手法は XOR 問題に対して、バイナリ値を入出力に設定した場合は高い学習成功率を示したが、実数値を入出力に設定した場合は、学習成功率は低かった。今後の課題として、

- 学習成功率の向上のために RPROP (Resilient back-propagation) (5) の採用の検討
- 関数近似 (回帰問題) が行える新たなモデルの開発
- FPGA, ASIC などのハードウェア上への搭載などが挙げられる。

(平成 23 年 11 月 9 日)

参考文献

- (1) 森江隆, "Artificial Neural Network LSI の設計法", 神経回路学会誌, Vol.10, No.2, pp.68-76, June 2003.
- (2) 黒柳奨, 岩田彰, "パルスニューロンモデルのための教師あり学習則", ニューロコンピューティング, pp. 95-102, May.1998.
- (3) 細井勇佑, 松尾和典, 黒川憲宏, 山本博康, 本木実, "ハードウェア化のための乗算器が不要なパルスニューロンモデル", 信学技報, ニューロコンピューティング NC2011-39, Vol.111, No.157, pp.87-92, July 2011.
- (4) 山田樹一, 黒柳 奨, 岩田 彰, "ニューロンモデルに存在する双対性を利用したニューラルネットワークのための教師あり学習手法", 電子情報通信学会論文誌 (D-II), Vol.J87-D-II, No.2, pp.399-406, Feb.2004.
- (5) RIEDMILLER M, "A direct adaptive method for faster back-propagation learning: the RPROP algorithm", Proceedings of the International Conference on Neural Networks 1, 586-591, 1993.