

## M-13

# パターン認識のためのパルス形ハードウェアニューラルネットワークモデルに対する検討

## A Study on Pulse-type Hardware Neural Network Model for Pattern Recognition

○眞下祐一<sup>1</sup>, 佐伯勝敏<sup>2</sup>, 関根好文<sup>3</sup>\*Yuichi Mashimo<sup>1</sup>, Katsutoshi Saeki<sup>2</sup>, Yoshifumi Sekine<sup>3</sup>

Abstract: Recently, many investigators have attempted to suggest a hardware neural network model for the engineering applications involving biological information processing.

In this paper, we propose a pulse-type hardware neural network model that specializes in image recognition and corresponds to high resolution images. As a result, we clarify the proposed pulse-type hardware neural network model is able to recognize various input data.

### 1. まえがき

近年、生体の脳が有する優れた情報処理能力を工学的に応用する非ノイマン型コンピュータが着目され、脳が持つニューラルネットワークのハードウェアモデルとその LSI 実装に関する研究が進められている<sup>[1]</sup>. これは現在広く利用されるノイマン型コンピュータとは異なる特徴を持ち、互いの欠点を補い合う相補的な関係が成り立つと期待される. 数百億個のニューロンが結合するニューラルネットワークは脳のシステム・アーキテクチャを構成し、パターン認識や予測、連想記憶等を可能とする. 中でも、シナプスにおける結合荷重が時々刻々と変化し、ネットワーク構成に影響を及ぼすシナプス可塑性と呼ばれる性質が情報処理に大きく関与すると報告されている<sup>[2]</sup>.

本稿では、脳の柔軟性に優れたパターン認識能力に着目し、その工学的応用を目的として、ニューロンの重要な構成要素であるシナプスモデルを設計した. さらに、本シナプスモデルを応用し、パルス形ハードウェアニューラルネットワークモデル(以下 P-HNN)を構成した場合の応答特性について検討を行う.

### 2. 本論

Fig.1 に今回検討に用いた P-HNN のネットワーク構成を示す. 100 個の cell をマトリクス状に縦 10 列、横 10 列並べた構成としており、隣り合う cell と相互結合する. 図中、cell は細胞体モデル<sup>[3]</sup>を表し、後述するシナプスモデルを用いて結合する. 1 個当たりの cell は入出力画像データの 1 画素に相当する. すなわち、高解像度な画像データに対応するためには大規模な P-HNN が必要となる. また、LSI は二次元的な配線構造であるため、P-HNN の大規模化に伴う配線が複雑になる. したがって、メタルに生ずる寄生素子による信号の遅

延や動作不良を避けるために、ネットワークの簡易化が必要となる. そこで、全 cell が入出力を担うため大規模化が容易で、且つネットワークの結合構成がシンプルなセルラニューラルネットワーク(以下 CNN)を用いる. さらに、本モデルは後述するシナプスモデル中の多値 SRAM により、単一の P-HNN のみで学習と認識を可能としており、細胞体モデルとシナプスモデルに用いる制御信号 WL で切り替えられる.




Fig.1 P-HNN.

Fig.2 にシナプスモデルのブロック図を示す. 本シナプスモデルは、結合した cell 間の発振順序と、それらの相対的な時間差に依存してシナプスの荷重値が変化する Spike Timing Dependent synaptic Plasticity(以下 STDP)<sup>[4]</sup>と呼ばれる性質を基にモデリングしている. 本モデルでは、STDP の学習則である対称型・非対称型時間窓特性を有する. CNN を用いた P-HNN に STDP を応用する場合、P-HNN を構成する cell の中で、初めに

1 : 日大理工・院(前)・電子    2 : 日大理工・教員・電子    3 : 日大名誉教授

発振する cell に対して結合するシナプスモデルは対称型時間窓特性を示す必要がある。これらのシナプスモデルが非対称型時間窓特性を示す場合、荷重値が減少し、他の cell と同期して発振できないという問題が生じる。そこで、結合した cell 間の発振順序を条件とし、学習則を制御可能なモデルとした。図中、時間窓生成回路が出力した電流は負荷容量が出力する荷重値を更新する。接地した負荷容量の蓄積データの損失を防ぐために、得られた荷重値を次段のメモリで保持する。本モデルでは、アナログ量である荷重値の量子化誤差を低減でき、且つリフレッシュが不要な多値 SRAM を用いる。最後に、多値 SRAM の出力電圧をカレント・シンクに入力し、荷重値に依存して出力電流を変化させることを可能としている。






Fig.2 Block diagram of synaptic model.


Fig.3 に細胞体モデル、およびシナプスモデルを応用して P-HNN を設計した場合における学習・認識時の入力パターンマトリクス図を示す。同図は Fig.1 に示すように、各格子に相当する座標の cell の入力パターンを表し、黒色はパルスを入力している状態、白色はパルスを入力していない状態を示す。図中、(a)は教師データとなる入力パターンを示し、一例としてアルファベットの“E”を示している。さらに、(b)~(g)は教師データのパターンを崩した入力パターンであり、これらを認識対象データとする。WL が High の状態において、P-HNN に教師データを入力すると、入力パターンと等しい出力パターンを示し、各シナプスモデルにおいて荷重値を更新する。WL を Low とし、得られた荷重値を多値 SRAM で保持した後、認識対象データを P-HNN に入力すると、保持した荷重分布が入力情報を補完し、P-HNN が教師データと同様のパターンを出力する。すなわち、本 P-HNN を用いて、教師データと認識対象データが同様のデータであると認識することが可能であることを確認した。




(a) Learning data




(b) Pattern 1




(c) Pattern 2




(d) Pattern 3



(e) Pattern 4



(f) Pattern 5



(g) Pattern 6

Fig.3 Input patterns for P-HNN.

### 3. まとめ

今回、パターン認識のための P-HNN の応答特性について検討を行った。P-HNN の構成要素であるシナプスモデルを新たに提案し、P-HNN を用いてパターン認識を行うことが可能であることを明らかにした。

今後は、VDEC を通して IC 化を行い、大規模なネットワークを構成した P-HNN の評価を行う予定である。

### 4. 参考文献

- [1] 森江隆, 石川聖二, 「知的画像認識技術と脳型 LSI 実装」, 信学誌, Vol.94, No.6, pp.459-463, 2011.
- [2] 工藤卓, 林勲, 田口隆久, 「神経細胞とシナプス可塑性」, SOFT, Vol.18, No.3, pp.362-368, 2006.
- [3] 眞下祐一, 佐伯勝敏, 関根好文, 「ロバスト性を有するパルス形ハードウェアニューロンモデルに対する一検討」, 電学電子回路研資, ECT-12-79, pp.99-102, 2012.
- [4] GBi, and M.Poo, “Synaptic modifications in culture hippocampal neurons. Dependent on spike timing synaptic strength, and postsynaptic Cell Type”, J.Neurosci, Vol.18, pp.10464-10472, 1998.