

## 進化するハードウェアによる引き込みの実現方法

7Q-5

岩田 昌也\*, 平尾 友二\*\*, 樋口 哲也\*

\*電子技術総合研究所, \*\*徳島県立工業技術センター

## 1. はじめに

進化するハードウェア (Evolvable hardware: EHW) [1]により, 引き込みを実現する方法を検討する。EHWは, 環境に応じて構造が自ら進化するハードウェアである。また, 引き込みは, パターン認識において, 未学習の入力に対して適切な結果を出力する機能であり, ニューラルネットワークの特徴的機能である。本稿では, EHWによる高速パターン認識器の実現への第1段階として, 典型的なパターン認識問題であるXOR(排他的論理和)問題について, EHWによる学習と引き込みが可能であることを示す。さらに, 引き込み能力を向上させる方法を検討し, 他の学習アルゴリズムと引き込み能力を比較する。

## 2. 進化するハードウェア (EHW)

EHWは, 環境に応じてハードウェア構造が自ら進化することを目的として, プログラム可能型論理素子(PLD)上の論理回路を, 遺伝的アルゴリズムを用いた学習で再構成していくハードウェアである。PLDは, ハードウェア構成を指定するビット列であるアーキテクチャビットをダウンロードすることにより, 様々な論理回路を構成できる。EHWでは, アーキテクチャビットを染色体として遺伝的アルゴリズムを適用し, 目的の機能との相違に基づく強化学習を行う。その結果, PLD上に進化した論理回路が得られる。EHWは, 環境適応の結果がハードウェアそのものであるため, ソフトウェアによる実行に比べて学習結果のシステムの実行速度がきわめて速いという特徴がある。

## 3. パターン認識と引き込み

パターン認識では, ノイズが加わり不完全な入力パターンも, 学習済みパターンとの類似性から, 正しく識別する機能が要求される。この機能は引き込みと呼ばれ, 人工ニューラルネットワーク (Artificial

Neural Network: ANN)の特徴的な機能である [2]。

一般的なパターン認識問題を扱うためには, 2次元特徴空間で非線形分離可能なパターンを識別することが必要条件となる。本稿では, 非線形分離可能性を調べる典型的な問題であるXOR問題を取り上げ, 学習と引き込みの実験を行う。

## 4. XOR問題の学習と引き込み

## 4.1 実験の概要

EHWによる, XOR問題の学習と引き込みのシミュレーション実験を行う。まずEHWに表1のXOR問題を学習させる。入力に加わるノイズも表現できるように, 入力値を3ビットで表現する。学習完了後, 学習パターンから入力値を1刻みで変化させたときのEHWの出力値を調べることにより, 2次元特徴空間での特徴分離面(決定表面)を求める。

比較のため, 他の学習アルゴリズムであるANN, ALN (Adaptive Logic Network), CS (Classifier System)についても同様の学習を行い, 決定表面を求める。

ALN [3]は, あらかじめ用意した二分木の各ノードに割り当てられた論理関数を, いくつかの法則に従って変更または削除し, 適切な論理関数を構成していく学習方法である。

CSは, プロダクションルールで使うif...then...ルールを遺伝的アルゴリズムで学習していくシステムである。ここでは, 論理関数の学習用に提案されているBOOLE [4]というCSで実験を行う。

## 4.2 実験結果

各学習アルゴリズムのパラメータを表2~表5に示す。学習完了後も, 理想的な決定表面が得られるまで学習を繰り返した。10回実験を行い, EHW, ALN, CSはそれぞれ平均1204, 299, 484世代で図1(a)の決定表面が得られた。なお, この図のX, Yの値は最大値111(2値)が1になるように正規化し

表1 学習パターン

X	Y	Z	
000	000	0	$Z = X\bar{Y} + \bar{X}Y$
000	111	1	X: $(X_2X_1X_0)$
111	000	1	Y: $(Y_2Y_1Y_0)$
111	111	0	

Implementation Method of Generalization Ability by using Evolvable Hardware

Masaya Iwata\*, Yuji Hirao\*\*, Tetsuya Higuchi\*

\*Electrotechnical Laboratory

\*\*Tokushima Prefectural Industrial Technology Center

表2 EHWのパラメータ

集団サイズ	50
染色体の長さ	104
交叉率	50%
交叉型	2点交叉
突然変異率	0.5%

表3 ANNのパラメータ

学習率	0.5
モーメント	0.3
中間層数	1
中間ノード数	2

表4 ALNのパラメータ

入力ノード数	16
ノード型	AND, OR, LEFT, RIGHT

表5 CSのパラメータ

集団サイズ	400
交叉率	50%
交叉型	1点交叉
突然変異率	0.5%
報酬	1000
誤り減衰率	80%
ワイルドカードバイアス	4

表6 学習したノイズパターン数と引き込み能力の関係

ノイズパターン数	0	8	12
EHW	1204	155	109
ALN	299	48	24
CS	1	5	7

※EHW, ALN: 図1(a)の決定表面の得られた世代数の平均  
 ※CS: 10回の実験中, 図1(a)の決定表面の得られた回数

を計8個, 12個追加してEHWに学習させ, それぞれ図1(a)の決定表面が得られる世代数を調べる。また, 比較のため, ALN, CSでも同様の実験を行う。




図1 実験で得られた決定表面

である。ANNは, Back Propagation法による10000回の学習で図1(b)の決定表面が得られた。なお, 各アルゴリズムにおける1世代の処理量は異なるので, 世代数の差は処理速度の差を表すものではない。

EHW, ALN, CSはANNと異なる決定表面が得られた。その理由は, EHW, ALN, CSが論理関数学習用アルゴリズムであり, それぞれ同一の論理関数  $Z = X_2 \bar{Y}_2 + \bar{X}_2 Y_2$  を学習したためである。この関数は, 入力の上位ビット( $X_2, Y_2$ )間のXORであり, 入力の上位ビットのみがパターン認識結果に関与した場合に理想的な引き込みが行われることを示している。このことは, 図1(a)の決定表面の境界が,  $X_2, Y_2$ の値が変わる境界と一致することからもわかる。

### 5. ノイズの加わったパターンの学習による引き込み能力の向上

#### 5.1 実験の概要

ANNは, 本来引き込み能力を持つため, 学習後は必ず図1(b)の決定表面が得られる。しかし, EHW, ALN, CSでは, 複数の学習結果の中で確率的に引き込み能力を持つ結果が出現するに過ぎない。本章では, EHWにANN並の引き込み能力を持たせることを目的として, ノイズの乗ったパターンを学習パターンに追加する。

表1のパターンに値1のノイズを乗せたパターン

### 5.2 実験結果

結果を表6に示す。EHW, ALN, CSとも, 学習するノイズパターン数の増加に伴い, 決定表面が得られやすくなっている。これより, ノイズパターンの学習は, EHW, ALN, CSの引き込み能力の増加に効果的であることがわかる。

### 6. おわりに

EHWでXOR問題の学習と引き込みが可能であることを確認した。したがって, EHWはパターン認識への応用に必要な最小条件を満たすと考えられる。また, ノイズの加わったパターンの学習が, EHWの引き込み能力の増加に効果的であることを確認した。他の学習アルゴリズムであるALN, CSでも同様の結論が得られた。

今後EHWの引き込み能力を改善することにより, ニューラルネットワークと同等の機能を持つ, 高速でコンパクトなパターン認識器がEHWで実現可能になると考えられる。EHWの引き込み能力の改善法として, EHWの構造をパターン認識向きに改良すること, EHWの学習の適応度評価に引き込みを促すパラメータを導入することなどが考えられる。

### 参考文献

- [1] Higuchi, T. et al., "Evolvable Hardware with Genetic Learning" in *Massively parallel Artificial Intelligence* (eds. H. Kitano), MIT Press, 1994.
- [2] Lippmann, R.P., "An Introduction to Computing with Neural Nets" *IEEE ASSP Magazine*, 4-22, April 1987.
- [3] Armstrong, W.W. and Gecsei, J., "Adaptation Algorithms for Binary Tree Network" *IEEE Trans. on SMC*, SMC-9, 276-285, 1979.
- [4] Wilson, S.W., "Classifier Systems and the Animal Problem" *Machine Learning*, 2, 199-228, 1987.