

# ルールベースニューラルネットワークの拡張

4L-3

- Hopfield Network への適用 -

田口敏裕 宮内新 石川知雄  
武蔵工業大学

## 1 はじめに

現在、ニューラルネットワークは神経回路網の仕組みを解明するモデルとして盛んに研究が行われている。ニューラルネットワークはニューロンの数が増えると、これらの積和演算の実行時間も増大し、出力値を得るのに時間がかかる。

そこで、我々は出力値を得る為の時間を短縮するために層構造ニューラルネットワークをルールに置き換えるルールベースニューラルネットワーク（以下RNN (Rule base Neural Network)）[1]を提案してきた。

本稿では、更なる汎用性向上の為に Hopfield Network に対応させる手法について報告する。

## 2 RNN

### 2.1 実現方法

層構造型 RNN は過去の手法 [2] の拡張である。まずこの多値を二値に変換し、ルールを導出する層構造型 RNN について簡単に触れておく。

#### 2.1.1 多値を扱う手段

多値を単純に二進数変換し、入力層の各ニューロンへ二値として入力する (図 2.1)。その二値の集合を一つのユニットとし、ニューラルネットワークを通して得た値を二値の集合で出力し、その結果を単純に十進数変換する。

#### 2.1.2 ネットワークの構成

二進化された十進数は一つのユニット群として定義され (図 2.2) する。ユニット群内部の各ユニット二値で表現され、縦の結合を行っている。このユニット群は

Extended rule base neural network

Toshihiro Taguchi, Arata Miyauchi, Tomo Ishikawa  
Musashi Institute of Technology

一般的なニューラルネットワークにおけるユニットに当てはめて考えることが出来る。




図 2.1: 入力層での入力値 (多値)-二値変換




図 2.2: ユニット群

#### 2.1.3 ルール導出手法

層構造型の RNN に於いては、適当ないくつかの入力と、教師信号をネットワークに与え、その入力と出力の対応を取り、それをルールとする。

そのルール導出の際には、入力から変換された二値に対し、多値に変換する前の二値のビットが 1 になるルールを生成し、その他の場合は 0 を出力するルールとする。この手法 [1] により、汎化能力を得ることが出来る。

## 3 提案手法

### 3.1 Hopfield Network

Hopfield Network は相互結合型をしており、エネルギー関数の値を小さくすることにより最適解を得る。

しかし、Hopfield Networkはいわゆる山登り法で有る為、局所解に陥る可能性が高い。

本手法では一旦ルールを生成すれば、解を出力する際の CPU 時間は殆ど問題とはならない為、局所解に陥りにくい Boltzman Machine を採用する。

### 3.2 ベクトル表現の採用

層構造型 RNN ではユニット群内を縦の結合をさせていたが、Hopfield Network における RNN ではユニット群を、一般的なニューラルネットワークとほぼ同じように扱え、かつ二進十進数がビット干渉を起こさないということから、ベクトルでユニット群を表現する。

ベクトル表現の際は、入力された十進数を単純に二進進化し、その各ビットをベクトルの各要素とする。各ユニット群間の積和演算の際には、二値ユニットの集合体であるユニット群を単純に十進進化し演算する。

## 4 検証実験

層構造型 RNN の検証実験では未知の LED データ識別実験を行った [1]。そこで、Hopfield Network における RNN の学習能力の検証をする為に、層構造型 RNN の検証実験と同様の LED 識別実験を行った。実験概要は以下に示す。

### 4.1 エネルギー関数

Hopfield Network は最適解算出の際にエネルギー関数を使用する。検証実験におけるエネルギー関数としては以下の式を作成し、使用した、

$$E = \min \left( \sum_{i=1}^7 |x_i(t) - (\text{各 LED 数字})_i| \right) \quad (4.1)$$

この式は、LED 各部分の階調値の差分の絶対値の総和が最も小さくなるものを選択することを示している。

### 4.2 学習と識別

これらを使ったネットワークに幾つか適当な入力を行い、式 4.1 のエネルギー関数の元に得た出力結果からルールを導出する。

学習は、各 LED 数字に於いて、階調値 2 と 3 の場合について学習させ、入力と出力との対応ルールを導出した。

識別対象である未知 LED 信号は図 4.1 に示す。総ての検証実験に於いて、この未知 LED 信号を利用した。




図 4.1: 未知の LED 信号

### 4.3 実験結果

図 4.1 の未知 LED 信号を識別させた結果を以下に示す。

実験の際、層構造型 RNN では 10 回の検証実験を、Hopfield Network における RNN では 100 回の検証実験を行った結果が、図 4.2 である。この結果を見る限り、Hopfield Network における RNN は識別能力も層構造型 RNN と比べて高く、より高い学習能力と汎化能力があることが確認できた。




図 4.2: 層構造型 RNN (左) と Hopfield Network における RNN (右) での識別結果

## 参考文献

- [1] 坪木 雅直、宮内 新、石川 知雄: “多値ニューラルネットワークからのルールベースの導出”、情報処理学会第 55 回全国大会、5AG-9(1997)
- [2] 山本 恵一、坪木 雅直、早川 祥、宮内 新: “ニューラルネットワークからのルールベースの導出”、電子情報通信学会総合大会、D-147(1996)