

# N-Queen 問題を対象としたマキシマムニューロンモデルの競合解消方式の提案

竹中要一<sup>†</sup> 船曳信生<sup>†</sup> 西川清史<sup>†</sup>

マキシマムニューロンモデルでは、制約条件の充足のため、互いに素に分割されたニューロングループの中で、最大ポテンシャル（ニューロン入力）を持つ唯一のニューロンを発火状態とする“winner-take-all”方式を採用している。我々は、Takefuji らによって提案されたマキシマムニューロンモデルが、制約条件充足型の組合せ最適化問題に対して、非常に有効なニューラルネットワーク解法を実現することを、N-Queen 問題を通して明らかにしてきた。本論文では、複数のニューロンが同時に同一の最大ポテンシャルを有する場合の、競合解消方式に関する提案を行う。 $N = 500$ までの N-Queen 問題に対するシミュレーションにより、ニューラルネットワークの 3 種類の状態更新方法（逐次、準同期、同期）における各方式の求解性能を評価し、“previous selection” 方式が優れていることを示す。また、提案する競合解消方式を用いた場合の準同期式マキシマムニューロンモデルが、大規模ニューラルネットワークのハードウェア実装に非常に適していることを示す。

## A Proposal of Competition Resolution Methods on the Maximum Neuron Model through N-Queens Problems

YOICHI TAKENAKA,<sup>†</sup> NOBUO FUNABIKI<sup>†</sup> and SEISHI NISHIKAWA<sup>†</sup>

The maximum neuron model provides efficient neural network solutions for combinatorial optimization problems. In this “winner-take-all” model, one and only one neuron with the maximum input value is always fired in each group of neurons to satisfy the selection constraint. The maximum neuron model can not only limit the searching space, but also reduce the computation load. In this paper, we propose two methods for selecting one neuron among two or more neurons which have the same maximum input value, named “least index method” and “previous selection method”. The simulation results in N-queens problems show that the latter method performs better than the former method generally, and that the previous selection method on the N-parallel mode provides the suitable algorithm for hardware implementation of large-scale neural networks.

### 1. まえがき

マキシマムニューロンモデルは、ニューラルネットワークによる組合せ最適化問題の効率的解法の実現のために Takefuji, Lee によって提案されたニューロンモデルである<sup>1)~3)</sup>。マキシマムニューロンモデルは、ニューロンレベルで組合せ最適化問題のグループ選択条件を満たすことにより、探索空間の大幅な縮小を実現している。グループ選択条件とは、ある特定のグループの中から 1 つのニューロンのみを選択する制約条件を意味している。グループ選択条件を有する組合せ最適化問題は多数存在する。その代表的な問題には、巡回セールスマン問題<sup>4)</sup>、VLSI 配線問題<sup>5),6)</sup>、グ

ラフ彩色問題<sup>7)</sup>、PLA 配線問題<sup>8)</sup>等があげられる。

マキシマムニューロンモデルは、これまでに総配線長が最短となるモジュール配置方向を求める Module Orientation 問題<sup>2)</sup>、グラフの最大 2 部グラフを求める Bipartite Subgraph 問題<sup>1)</sup>、チェス盤上に  $N$  個のクイーンを互いの利き筋に当たらぬように配置する N-Queen 問題<sup>9)</sup>に適用され、求解性能の向上が報告されている。

マキシマムニューロンモデルは、グループ選択条件の常時充足を実現する。そのため、解空間を構成するニューロンをグループ選択条件に対応したグループに分割し、各グループの中でただ 1 つのニューロンを発火状態にする。すなわち、発火するニューロンを決定する方式に“winner-take-all” 方式を採用している。マキシマムニューロンモデルにおける各グループは、互いに素となるように構成されている。すなわち、

<sup>†</sup> 大阪大学基礎工学部

Faculty of Engineering Science, Osaka University

各ニューロンは唯一のグループにのみ所属している。発火すべきニューロンとして、各グループの中で最大のポテンシャル、つまり最大のニューロン入力を持つニューロンが選択される。

組合せ最適化問題を解くための我々の提案するニューラルネットワークでは、計算量の減少、状態数低減による解探索性能の向上を狙いとして、ニューロン入力値に限られた範囲の整数値を採用している<sup>9),10)</sup>。このためマキシマムニューロンモデルを用いた場合、各グループ内で複数のニューロンが同時に同一の最大ポテンシャルを持つ場合が生じる。しかしながら、これまで、このような場合の競合解消方式に関する研究はなされてこなかった。そこで本論文では N-Queen 問題を対象として、マキシマムニューロンモデルにおいて、複数のニューロンが同時に最大ポテンシャルを有する場合の競合解消方式に関する提案を行う。N = 500 までの N-Queen 問題に対するシミュレーションにより、ニューラルネットワークの 3 種類の状態更新方法（逐次、同期、準同期）における各競合解消方式の求解性能を評価する。さらに、提案する競合解消方式を用いてニューラルネットワークをデジタル回路上にハードウェア実装する場合における記憶領域、バス幅に関する評価を行う。

## 2. N-Queen 問題とマキシマムニューロンモデル

### 2.1 N-Queen 問題の定義

N-Queen 問題とは、 $N \times N$  の拁目のチェスボード上に、 $N$  個の Queen を互いの利き筋に当たらないように配置する問題である。Queen は図 1 に示すように縦、横、斜めに移動できるため、本問題では次の 4 つの制約条件を同時に満足することが要求される<sup>9)~11)</sup>。

- 制約条件 1) 各行に必ず 1 個の Queen を配置する
- 制約条件 2) 各列に必ず 1 個の Queen を配置する
- 制約条件 3) 右斜めに 2 個以上の Queen を配置しない
- 制約条件 4) 左斜めに 2 個以上の Queen を配置しない

上記の制約条件 1) および、制約条件 2) がグループ選択条件に対応している。

### 2.2 マキシマムニューロンモデル

マキシマムニューロンモデルは、各ニューロンが 0 または 1 の値をとるバイナリニューロンで構成される。そして、解空間を構成するニューロン全体を互いに素

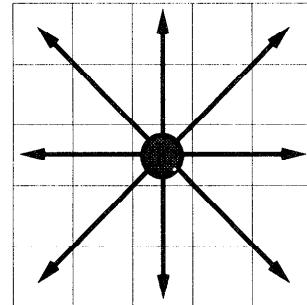


図 1 Queen の動作  
Fig. 1 A motion of a Queen.

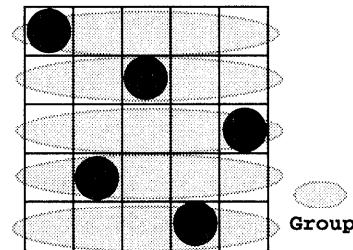


図 2 グループの構成例 ( $N = 5$ )  
Fig. 2 An example of a neuron group configuration.

なグループに分け、グループ内で入力値最大のニューロンのうち 1 つのみが出力値 1 をとる。N-Queen 問題の解法では、合計  $N^2$  個のニューロンを使用し、 $i$  行  $j$  列のニューロン出力  $V_{ij} = 1$  はチェスボードの  $i$  行  $j$  列の拁目に Queen を配置することを、 $V_{ij} = 0$  は配置しないことを表現するものと定義する。

本論文では 2 つのグループ選択条件のうち、制約条件 1) をマキシマムニューロンモデルで充足させる。すなわち、各行に対応した  $N$  個のニューロンごとにグループを構成する。そして、各グループに所属する  $N$  個のニューロンの中で入力値最大のニューロンが出力値 1 をとるように、マキシマムニューロンモデルを適用する。これを式で表すと、

$$V_{ij} = \begin{cases} 1 & \text{if } U_{ij} = \max(U_{i1}, U_{i2}, \dots, U_{iN}) \\ 0 & \text{otherwise} \end{cases} \quad (1)$$

となる。ここで、 $U_{ij}$  は  $i$  行  $j$  列のニューロン入力値を表し、 $\max()$  は値が最大の引数を返す関数である。図 2 に 5-Queen 問題におけるマキシマムニューロンモデルにおけるグループの構成例を示す。

### 2.3 2 種類の “winner-take-all” 競合解消方式

マキシマムニューロンモデルは、構成するグループ内で入力値最大のニューロンをただ 1 つ選択する。このとき、入力値最大のニューロン（選択候補）が 2 つ以

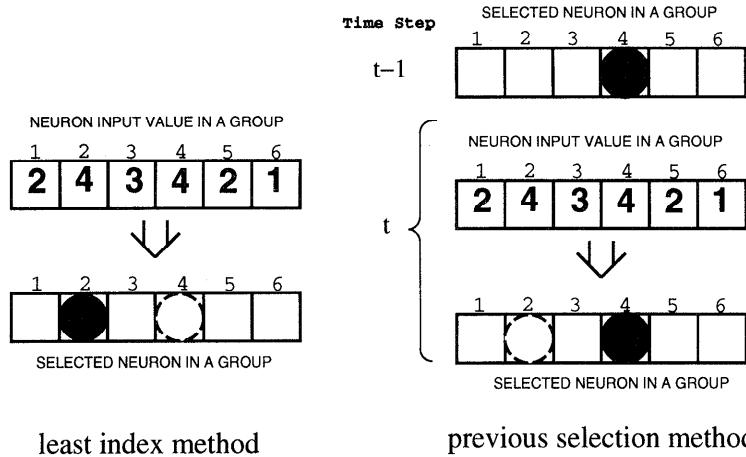


図3 2種類の競合解消方式

Fig. 3 Two competition resolution methods.

上存在する場合でも、マキシマムニューロンモデルの定義により、1つのニューロンのみが選択されねばならない。このような場合の競合解消方式として，“least index” 方式 および，“previous selection” 方式を提案する。

least index 方式とは、選択候補が2つ以上存在する場合、つねに添字の最も小さいニューロンを選択する方式である。previous selection 方式とは、選択候補の中に直前に選択されていたニューロンがあればそれを優先的に選択し、直前に選択されていたニューロンがなければ、最も添字の小さいニューロンを選択する方式である。図3に、6個のニューロンによって構成されるグループに対する、least index 方式と previous selection 方式の違いを示す。ここで各樹目内の数字は各ニューロンの入力値を表す。least index 方式では、ニューロン入力値が4である2つの選択候補の中から添字の小さい（この場合では2番目の）ニューロンが選択されている。一方、previous selection 方式では同じ選択候補のうち、前回選択されていた4番目のニューロンが選択されている。

この2つの方式の特長は、乱数発生関数を用いないため、導入にともなうソフトウェア量、ハードウェア量の増加を最小限におさえることができること、および選択結果が決定的となることにある。2つの方式を比較した場合、previous selection 方式の方が、ニューラルネットワークの状態変化が生じにくくと考えられる。また、previous selection 方式では、直前に選択されていたニューロンの参照を行うため、計算量は least index 方式より比較計算1回分多くなる。

### 3. マキシマムニューロンモデルを用いた解法

#### 3.1 エネルギー関数

エネルギー関数は、組合せ最適化問題の制約条件を表す非負関数である。N-Queen 問題の4つの制約条件のうち、マキシマムニューロンモデルが充足する制約条件1) を除いた、3つの制約条件に対応した3つの項から構成されるエネルギー関数  $E$  を採用している<sup>9)</sup>。

$$E = \frac{A}{2} \sum_{j=1}^N \left( \sum_{k=1}^N V_{kj} - 1 \right)^2 + \frac{B_1}{2} \sum_{i=1}^N \sum_{j=1}^N V_{ij} \sum_{\substack{1 \leq i+k, j+k \leq N \\ k \neq 0}} V_{i+k, j+k} + \frac{B_2}{2} \sum_{i=1}^N \sum_{j=1}^N V_{ij} \sum_{\substack{1 \leq i+k, j-k \leq N \\ k \neq 0}} V_{i+k, j-k} \quad (2)$$

$A$  項は、各列に必ず1つ Queen を配置する条件を表している。 $B_1$  項は右斜め方向に、 $B_2$  項は左斜め方向に2つ以上 Queen を配置しない条件を表している。エネルギー関数の値が0となるときに、ニューロンの出力値は制約条件をすべて満たした解を表現している。

#### 3.2 動作方程式

エネルギー関数の値を0とするニューロン出力値の探索のために、最急降下法である動作方程式を用いる。 $i$  行  $j$  列のニューロンに対する動作方程式を、式(3)に示す。

$$\begin{aligned}
 \frac{dU_{ij}}{dt} &= -\frac{\partial E}{\partial V_{ij}} \\
 &= -A \left( \sum_{k=1}^N V_{kj} - 1 \right) \\
 &\quad - B_1 \left( \sum_{\substack{1 \leq i+k, j+k \leq N \\ k \neq 0}} V_{i+kj+k} \right) \\
 &\quad - B_2 \left( \sum_{\substack{1 \leq i+k, j-k \leq N \\ k \neq 0}} V_{i+kj-k} \right) \quad (3)
 \end{aligned}$$

ここで、 $A, B_1, B_2$  は  $A = B_1 = B_2 = 1$  で与えられる係数である。 $t$  は、動作方程式を一次オイラー法で解く場合の更新回数を表す。

ニューロン入力値には、上下限制限を行っている。これはデジタル回路上でのハードウェア実装に不可欠である。また、ニューラルネットワークの状態変化が生じやすくなり、解への収束能力を高める効果もある。

$$\begin{aligned}
 \text{if } U_{ij} > U_{\max} \text{ then } U_{ij} &= U_{\max} \\
 \text{if } U_{ij} < U_{\min} \text{ then } U_{ij} &= U_{\min} \quad (4)
 \end{aligned}$$

ここで  $U_{\max}$  および  $U_{\min}$  はそれぞれニューロン入力値の最大値、最小値である。なお、本論文では  $(U_{\max} - U_{\min})$  を便宜のためニューロン範囲と呼ぶこととする。

### 3.3 3種類の状態更新方法

ニューラルネットワークでは、動作方程式によりニューロン入力値を更新し、ニューロン関数により出力値を更新する。ニューロン入力値に  $U_{\min} \sim U_{\max}$  の整数の一様乱数を用いて初期値を与えた後、出力値の更新を繰り返すことにより、ニューラルネットワークは解の探索を行う。このとき、同時に更新を行うニューロン数の違いによって、逐次式、同期式、準同期式の3種類の更新方法が存在する<sup>9)</sup>。

逐次式更新では、同時に1つのニューロンの状態のみを更新する。同期式更新では、同時にすべてのニューロンの状態を更新する。すなわち、すべてのニューロンの入力値の更新後、すべてのニューロンの出力値を更新する。準同期式更新では、各行ごとに分けられた  $N$  個のグループに対し、各グループに属する  $N$  個のニューロン状態を同時に更新し、グループ間は逐次的に更新する。これら3つの更新方法を同期式並列計算機の最大プロセッサ数に対応させた場合、逐次式はプロセッサ数1、同期式は  $N^2$ 、準同期式は  $N$  に対応する。

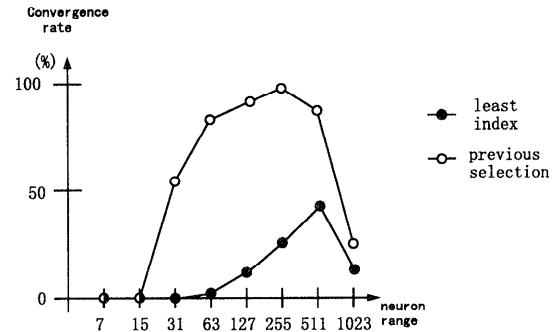


図4 500-Queen 問題の同期式におけるニューロン範囲と収束率の関係

Fig. 4 Relationship between the neuron input range and the convergence rate of the  $N^2$ -parallel mode on 500-Queens problems.

## 4. シミュレーションとハードウェア実現性

### 4.1 シミュレーション条件と結果

2種類の競合解消方式の性能比較を行うため、 $N = 10 \sim 500$  の 10種類の N-Queen 問題に対する 3種類の状態更新方法でのシミュレーションを行った。各問題に対し、異なるニューロン入力値の初期値を用いて 100 回の試行を行い、収束率および平均更新回数を求めた。収束率とは 100 回の試行のうち、解に収束した割合を表す。平均更新回数とは収束した場合の更新回数の平均値である。ただし、最大更新回数を 1000 回とし、それまでに各ニューロンが収束しなければ収束失敗と見なした。

ここで、各シミュレーションに用いたニューロン範囲は、逐次式更新および準同期式更新では、 $U_{\max} = 15 (= 2^4 - 1)$ ,  $U_{\min} = 0$  とした。同期式は、逐次式や準同期式よりも多数のニューロンが同時に変化し振動的になりやすいため、ニューロン範囲を広くする必要があることが明らかにされている<sup>12)</sup>。そこで、本論文では 500-Queen 問題において、ニューロン範囲と収束率の関係を示す図4より、十分な収束率が得られる最小のニューロン範囲である  $U_{\max} = 63 (= 2^6 - 1)$ ,  $U_{\min} = 0$  とした。

表1に逐次式更新、表2に同期式更新、表3に準同期式更新における least index 方式と previous selection 方式のシミュレーション結果を示す。

### 4.2 least index 方式と previous selection 方式の性能比較

逐次式更新では、 $N = 10$  で least index 方式が収束率において優れているものの、 $N \geq 20$  で previous selection 方式が収束率、平均更新回数ともに優れている。つまり、previous selection 方式の性能が優れて

表 1 逐次式更新方法におけるシミュレーション結果  
Table 1 Simulation results on the sequential mode.

N	least index		previous selection	
	収束率	平均回数	収束率	平均回数
10	36%	38.1 (回)	31	22.5
20	42	48.2	48	32.9
30	61	53.1	62	45.7
50	75	57.5	86	48.2
100	99	58.0	96	49.8
150	100	61.7	99	50.5
200	100	57.7	100	50.7
300	100	59.4	100	54.1
400	100	59.4	100	57.7
500	100	62.7	100	59.4

表 2 同期式更新方法におけるシミュレーション結果  
Table 2 Simulation results on the  $N^2$ -parallel mode.

N	least index		previous selection	
	収束率	平均回数	収束率	平均回数
10	42%	110.1 (回)	26	71.2
20	48	176.6	47	142.0
30	64	189.5	53	148.3
50	73	187.8	78	176.6
100	83	192.7	99	174.2
150	55	182.4	95	151.8
200	39	177.3	95	152.7
300	23	186.5	95	152.8
400	5	193.8	87	152.6
500	3	157.7	86	139.4

表 3 準同期式更新方法におけるシミュレーション結果  
Table 3 Simulation results on the  $N$ -parallel mode.

N	least index		previous selection	
	収束率	平均回数	収束率	平均回数
10	38%	27.0 (回)	32	16.7
20	51	47.6	47	36.2
30	67	44.7	54	41.0
50	84	50.1	79	45.3
100	94	46.2	97	47.6
150	99	39.6	99	46.5
200	97	38.4	100	45.9
300	92	40.6	100	49.0
400	89	41.1	100	47.9
500	79	42.7	99	50.6

いるといえる。

同期式更新では、問題サイズが小さい ( $N \leq 30$ ) 場合は、least index 方式の方が収束率が高い。しかし、least index 方式は問題サイズが大きくなる ( $N \geq 200$ ) になると収束率が非常に悪化する。一方、previous selection 方式では問題サイズが大きい場合も、収束率は 85%以上と高く、previous selection 方式の性能が優れているといえる。

準同期式更新では、逐次式更新や同期式更新に比べると競合解消方式が性能に与える影響は小さい。しか

し、問題サイズが大きい場合において、収束率がほぼ 100%である previous selection 方式が優れているといえる。

以上をまとめると、2種類の競合解消方式について、(1) 3種類の状態更新方法いずれにおいても、一般的に previous selection 方式が優れている、(2) 競合解消方式がニューラルネットワークの性能に与える影響は、同期式更新で最も大きく、準同期式更新で最も小さい、といえる。

#### 4.3 考 察

3種類の更新方法において、マキシマムニューロンにおける2種類の競合解消方式の性能をシミュレーションにより比較した結果、previous selection 方式が優れていることが明らかになった。この理由は、previous selection 方式が least index 方式よりもニューロンの状態を保持する能力が高いためであると考えられる。ニューラルネットワークでは、各ニューロンは他のニューロンの状態に依存して状態を更新する。したがって、他のニューロンの状態変化が多くなると自状態の変化も多くなり収束が困難となる。それを避けるためには、状態を保持する能力が高い previous selection 方式が優れていると考えられる。

#### 4.4 ニューロン範囲のマキシマムニューロンモデルに与える影響

デジタル回路上でのニューラルネットワークの実装を考えた場合、各ニューロンの記憶容量、入力バス幅はニューロン範囲の対数に等しくなるため、ニューロン範囲は狭い方が望ましい<sup>13)</sup>。そこで、準同期式における previous selection 方式について、ニューロン範囲を狭くした場合の性能評価を行った。準同期式は収束性能が優れており、並列度も問題の大きさ  $N$  であるため、3種類の状態更新方法の中では最もハードウェア化に適していると考えられる。シミュレーションではニューロン範囲にバス幅 2, 3 に対応する 0~3, 0~7 の2種類を採用した。表 4 にシミュレーション結果を示す。

問題サイズの小さい ( $N \leq 50$ ) 場合、ニューロン範囲が狭くなるに従って、若干収束率が悪化している。問題サイズが大きい場合、ほぼ 100%の収束率を維持しながら平均更新回数が減少しており、逆に性能の向上が見られる。すなわち、previous selection 方式の準同期式更新を採用した場合、ニューロンあたりわずか 2ビットのバス幅、記憶容量で N-Queen 問題を並列かつ効率的に解くハードウェアが実現できることを示している。

表 4 準同期式 previous selection 方式のシミュレーション結果  
Table 4 Simulation results of previous selection method on the N-parallel mode.

ニューロン範囲 <i>N</i>	0~3		0~7	
	収束率	平均回数	収束率	平均回数
10	27%	4.3 (回)	19	10.3
20	20	8.4	27	16.4
30	15	9.3	48	18.0
50	42	12.7	67	23.2
100	82	14.0	91	25.1
150	95	14.9	99	26.6
200	100	16.7	100	24.9
300	99	15.4	100	26.6
400	99	15.1	100	27.9
500	100	16.7	100	30.1

#### 4.5 ハードウェア実現性評価

デジタル回路上に大規模ニューラルネットワークのハードウェアを実現する場合に問題となるのが、ニューロン間結合配線の実装および各ニューロンの入出力値用記憶装置の実装である。準同期式更新において、ニューロン間結合配線の増加を抑制するハードウェアとしては、山下ら<sup>14)</sup>や高橋ら<sup>15)</sup>の方法の拡張方法<sup>12)</sup>が提案されている。これらの方では、プロセッサ間はバス結合されており、プロセッサ間の通信については、発火状態にあるニューロンだけが自分のID番号をアビターを用いてバスに乗せる方式を採用している。図5に、マキシマムニューロンモデルをN入力比較器を導入することにより実現したハードウェアを示す。Processor *i*は、*i*列目のニューロンの状態保持と計算を行い、各行を同期的に各列を逐次的に更新する。従来のニューロンモデルでは、各行で発火状態にあるニューロン数が最大*N*となるため、各行の更新時に必要な通信量が $O(N)$ であった。一方、マキシマムニューロンモデルでは、発火状態にあるニューロンは各行で必ず1つであるため、通信量を $O(1)$ へと大幅に削減することができる。また、各行で複数のニューロンが発火している場合と異なり、バス上での通信情報の衝突を考慮する必要がなくなるためバスの同期処理も容易となる。*N*入力比較器を要するハードウェア量と計算時間はトレードオフの関係にある。 $N \times N$ 再構成メッシュを用いることにより $O(1)$ 時間の*N*入力比較器が実現可能である<sup>16)</sup>が、 $O(N^2)$ のハードウェア量が必要とする。一方、プロセッサに比較を行わせることにより、ハードウェア量の増加を最小限におさえられるが、計算時間が $O(n \log n)$ となる。

大規模ニューラルネットワークのハードウェアを実現する場合に最も大きな制約となるのがニューロン入力値の記憶領域である。これは、ニューロン間結合配線に

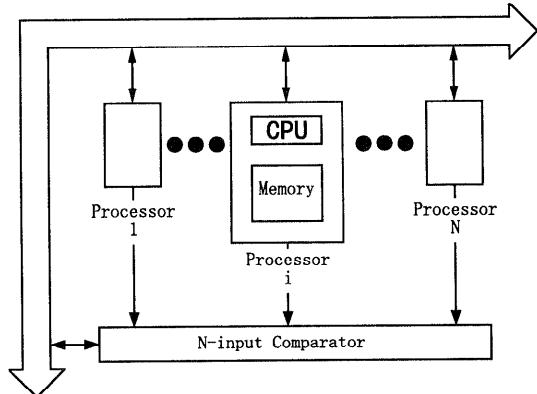


図 5 準同期式のハードウェア構成

Fig. 5 A hardware system for the N-parallel method.

対する制約は、バス等を用いて転送の並列度を犠牲にすることによりある程度緩和することが可能であるが、ニューロン入出力値の記憶領域はニューロン数に応じて必ず必要となるためである。前述のシミュレーションから、準同期式更新方法の previous selection 方式では各ニューロン入力値の記憶領域にわずか2ビットしか必要としないことが分かる。また、ニューロン出力値の記憶領域も各ニューロングループごとに、その発火ニューロンのインデックスを表す $\log N$ ビットあればよい。これにより、N-Queen 問題に対し、ニューロン入力値に $2N^2$ ビット、出力値に $N \log N$ ビット用意すればよく、提案するマキシマムニューロンモデルがニューラルネットワークの並列ハードウェア化に適したモデルであるといえる。

#### 5. む す び

本論文では、マキシマムニューロンモデルにおける2種類の“winner-take-all”競合解消方式として、least index 方式および、previous selection 方式を提案した。N-Queen 問題を通じて各方式の求解性能を、3種類の状態更新方法におけるシミュレーションにより評価した。その結果、previous selection 方式が全般的に優れていることが分かった。また、準同期式の previous selection 方式では、わずか2ビットのニューロン範囲で良好な収束性能を得られることを示した。さらに、提案するマキシマムニューロンモデルを用いてハードウェアを実装する場合におけるハードウェア量の評価を行い、従来のニューロンモデルを用いて実装した場合と比較して、大幅なハードウェア量の削減を行えることを示した。

## 参考文献

- 1) Lee, K., Funabiki, N. and Takefuji, Y.: A Parallel Improvement Algorithm for the Bipartite Subgraph Problem, *IEEE Trans. Neural Networks*, Vol.3, No.1, pp.139–145 (1992).
- 2) Takefuji, Y. and Lee, K.: An artificial maximum neural network: A winner-take all neuron model forcing the state of the system in a solution domain, *Biol. Cybern.*, Vol.67, pp.243–251 (1992).
- 3) Lee, K. and Takefuji, Y.: A Generalized maximum neural network for the module orientation problem, *Int. J. Electronics*, Vol.72, pp.331–355 (1992).
- 4) Hopfield, J. and Tank, D.: Neural computation of decisions in optimization problems, *Biol. Cybern.*, Vol.52, pp.141–152 (1985).
- 5) Funabiki, N. and Takefuji, Y.: A parallel algorithm for channel routing problems, *IEEE Trans. Computer-Aided Design*, Vol.11, No.4, pp.464–474 (1992).
- 6) Funabiki, N. and Nishikawa, S.: A neural network model for multilayer topological via minimization in a switchbox, *IEEE Trans. Computer-Aided Design*, Vol.15, pp.1012–1020 (1996).
- 7) Takefuji, Y. and Lee, K.: Artificial neural networks for four-coloringmap problems and K-colorability problems, *IEEE Trans. Circuits Systems*, Vol.38, pp.326–333 (1991).
- 8) Tsuchiya, K. and Takefuji, Y.: A Neural Network Approach to PLA Folding Problems, *IEEE Trans. Computer-Aided Design*, Vol.15, pp.1299–1305 (1996).
- 9) 竹中要一, 舟曳信生, 西川清史: マキシマムニューロンを用いた N-Queen 問題のニューラルネットワーク解法の提案, 情報処理学会論文誌, Vol.37, No.10, pp.1781–1788 (1996).
- 10) Takefuji, Y.: *Neural Network Parallel Computing*, Kluwer Academic Publishers (1992).
- 11) Mandziuk, J.: Solving the N-Queens problem with a binary Hopfield-type network, *Biol. Cybern.*, Vol.66, pp.375–379 (1995).
- 12) 由雄宏明, 馬場孝之, 舟曳信生, 西川清史: N-Queen 問題を対象としたニューラルネットワークの半同期式更新方法の提案, 電子情報通信学会論文誌, Vol.J80-A, No.1, pp.205–212 (1997).
- 13) Kurokawa, T. and Yamashita, H.: Bus connected neural network hardware system, *Electronics Letters*, Vol.30, pp.979–980 (1994).
- 14) 山下博司, 黒川恭一, 古賀義亮: 相互結合型バイナリーニューラルネットワークのハードウェア化, 電子情報通信学会論文誌, Vol.J77-D-II, No.10, pp.2130–2137 (1994).
- 15) 高橋潤, 黒川恭一, 尾田孝典, 山瀧倫明, 古賀義亮: マルチ DSP システムを用いたニューラルネットワークの実現, 電子情報通信学会論文誌, Vol.J78-D-II, No.6, pp.989–991 (1995).
- 16) Madhusudan, N. and Sartaj, S.: Sorting  $n$  Numbers on  $n \times n$  reconfigurable meshes with buses, *J. Parallel and Distributed Computing*, Vol.23, pp.37–48 (1994).

(平成 8 年 12 月 2 日受付)

(平成 9 年 9 月 10 日採録)

## 竹中 要一 (正会員)



昭和 48 年生. 平成 4 年大阪大学基礎工学部情報工学科入学. 平成 7 年同大大学院博士前期課程入学.

平成 9 年同博士前期課程修了. 現在, 同博士後期課程在学中. ニューラル

ネットワーク, 組合せ最適化問題, 計算幾何学に関する研究に従事. IEEE, 電子情報通信学会各会員.

## 舟曳 信生 (正会員)



昭和 59 年東京大学工学部計数工学科卒業. 同年住友金属工業(株)

入社. 平成 3 年米国ケースウエスタンリザーブ大学大学院修士課程修了.

平成 6 年大阪大学基礎工学部情報工学科講師. 現在, 同助教授. 工学博士. ニューラル

ネットワーク, 組合せ最適化問題, プロセス制御等に関する研究に従事. IEEE, 電子情報通信学会各会員.

## 西川 清史 (正会員)

昭和 40 年東京大学工学部電子工学科卒業. 昭和 45 年同大大学院工学系研究科博士課程修了. 工学博士.

同年日本電信電話公社(現 NTT)入社. 同社基礎研究所, 情報通信処理研究所, コミュニケーション科学研究所所長などを経て, 平成 5 年より大阪大学基礎工学部情報工学科教授となり現在に至る. ハードウェア

設計法, 並列アーキテクチャ, 最適化問題の解法などの研究に従事. 電子情報通信学会, IEEE, ACM 各会員.