

任意構造神経回路網 FCN による自律エージェントの行動制御

田澤和子[†] 長尾智晴[†]

従来の神経回路網は、与えられた問題に応じて階層構造型や相互結合型など基本構造を選択し、対応する学習方法を用いて結合荷重やしきい値を調整するのが一般的である。しかし、あらかじめ選択した構造による神経回路網によって、与えられた問題に対する解を必ず導けるとは限らない。そこで本論文では、適切な構造が未知であるエージェントの行動制御問題に対し、ただ1つの手法により必要とする任意の神経回路網を獲得するための手法として、Flexibly Connected Neural Networkを提案する。また、エイリアス問題を含む迷路探索での自律エージェントの行動決定に提案手法を適用し、その有効性を示すとともに、獲得された神経回路網の解析結果について述べる。

Behavior Control of an Autonomous Agent Using Flexibly Connected Neural Network; FCN

KAZUKO TAZAWA[†] and TOMOHARU NAGAO[†]

In general, the structure of neural network, such as the layered type or the mutually connected type, etc., is chosen as to the problem. And weights and thresholds of neural network are usually adjusted by the learning method corresponding to the structure. Some given problems, however, cannot be always solved by the neural network of the structure decided beforehand. Here we present Flexibly Connected Neural Network as a method of constructing arbitrary neural network with optimized structure and parameters to solve unknown problems. In order to examine the effectiveness, we applied the proposed method to behavior control of an autonomous agent with perceptual aliasing, and analyzed the acquired neural network.

1. はじめに

神経回路網は脳の情報処理方式を模倣することを目的として、実際の生物の神経回路網をモデル化したものである。神経細胞に対応する単純な情報処理ユニットを多数結合することで、並列分散型情報処理を行う。主な特徴の1つとして、従来の実行プログラムのように事前にすべての処理手順を詳細に記述するのではなく、神経回路網自らが環境に合わせて学習することによって認識対象に存在する規則性を見出し、未知の問題へ柔軟に対応することが可能である点があげられる。神経回路網は様々な角度から研究が進められており、パターン認識や予測といった問題に対して高い有効性が示されている¹⁾。しかし現在、エージェントの行動制御においては神経回路網よりも遺伝的プログラミングや強化学習を用いる方法が主流である。ただし、これらの方法にはいくつかの問題点があげられる。遺伝的

プログラミングにおいては、作成者が設定する終端・非終端記号によってその問題が解けるか否かが大きく左右される。強化学習においても、複雑な問題では状態数の増加などの問題が残っている。

エージェントの行動制御では、過去のエージェントの行動が次の行動決定に大きく依存することが多く、周囲の環境はつねに動的に変化していく。そのため、神経回路網には時系列信号を処理する能力が求められ、包括的なルールを蓄えることができる構造が必要とされる。しかし、いまだ適切な神経回路網の構造は決定されていない。従来の神経回路網では、階層構造型や相互結合型など、あらかじめ用意された結合構造を用いるのが一般的である。また、その学習対象は神経回路網の結合荷重としきい値であり、回路網の構造には何ら影響を与えない。そのため、あらかじめ用意した回路網の構造を用いて問題に対する解を必ず導けるといふ前提が必要となる。つまり、エージェントの行動制御のように、適切な構造が未知である問題に対しては、ただ1つの手法を用いて必要な神経回路網の構造を決定すると同時に、結合荷重やしきい値も決定する

[†] 横浜国立大学大学院環境情報学府
Graduate School of Environment and Information Sciences, Yokohama National University

手法が有効であると考えられるため、これを実現することが本研究の目的である。

筆者らが属する研究グループは、学習方法に遺伝的アルゴリズム (GA) を用いて神経回路網の結合荷重と構造を自動決定し、任意の結合構造を持つ神経回路網を獲得する方式を提唱している^{2),3)}。GA と神経回路網を融合する手法としては他に以下のような研究があげられる。まず、高橋らによって行われた誤差逆伝播学習法に必要なパラメータの決定⁴⁾がある。また、de Garis⁵⁾、Montana⁶⁾、Whitley⁷⁾、Kitano⁸⁾による神経回路網の構造決定がある。さらに、Ono⁹⁾、Sang-Woo¹⁰⁾によって神経回路網によるエージェントのコントロールも行われている。これらの研究はいずれも優れた成果を残しているが、生成される構造に制限が設けられている。

本論文では、任意の結合構造を持った神経回路網の獲得のために、文献 2), 3) の方法を発展させた Flexibly Connected Neural Network を提案する。また、本手法の適用事例としては、強化学習の分野における例題として知られているエイリアス問題を含む迷路でのエージェントの行動決定を扱う。エイリアス問題を解くためにはエージェントが以前に行った行動を記憶するための仕組みが必要であり、その実現のために必要な構造は未知である。よって、このような問題に本手法を適用し、その有効性を検証することは有意義である。さらに、獲得された神経回路網の構造を解析することにより、記憶能力の取扱いに適した構造が獲得されているか否かを考察する。本論文では 2 章で提案手法について述べる。3 章では迷路探索問題について説明し、4 章ではエージェントの行動決定問題に対する本手法の適用事例を示す。さらに 5 章では獲得された回路網の解析結果について述べ、6 章で本論文を総括する。

2. Flexibly Connected Neural Network (FCN)

2.1 FCN の特徴

図 1, 表 1 に FCN の構造図および結合荷重としきい値の一覧表の例を示す。構造図と表は 1 対 1 に対応している。これらをもとに FCN の特徴を次に示す。

構造

- FCN の各ユニットは相互 (自己) 結合が可能である。ただし各ユニットから入力ユニットへの信号伝播は禁止とする。

FCN では、入力ユニットはセンサ、出力ユニットはアクチュエータと考えている。そのため、中間・出

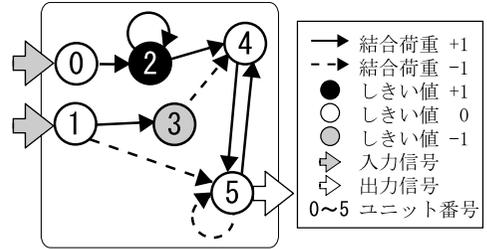


図 1 FCN の構造例
Fig. 1 A structure of FCN.

表 1 結合荷重・しきい値表
Table 1 Connection weights and thresholds of the FCN shown in Fig.1.

From Unit	No.	To Unit					
		Input	Hidden			Output	
Input sensory	0	*	*	+1	0	0	0
	1	*	*	0	+1	0	-1
Hidden	2	*	*	+1	0	+1	0
	3	*	*	0	0	-1	0
	4	*	*	0	0	0	+1
Output	5	*	*	0	0	+1	-1
Thresholds		*	*	+1	-1	0	0

* : forbidden

力ユニットが自分自身の影響を受けることは自然であるが、入力ユニットが自身を含めた神経回路網内部からの信号を受けることは不自然な動作と考えられる。そのため各ユニットから入力ユニットへの信号伝播を禁止している。

結合荷重

- 結合荷重は $\pm 1, 0$ とする。+1 は発火性結合、-1 は抑制性結合、0 は結合が存在しないことを表す。

FCN では $\pm 1, 0$ という単純な値の結合荷重を GA によって最適化することで、任意性の高い神経回路網を獲得する。これにより、エージェントの行動制御のように最適な神経回路網の構造が未知の問題に対しても問題を解くことが可能となる。また、初期回路網群生成時および突然変異発生時の結合荷重の出現比率は、0 が 50%、 ± 1 は各 25% とする。結合の有無の比率は、結合がない部分の比率を上げすぎても下げすぎても、最適化の妨げになるため経験的に 50% とした。このように最も単純な 3 値の結合荷重を用いた場合も、ユニット数を増やすことにより複雑に動作する回路網を構築することが可能であると考えられる。

また、結合荷重およびしきい値が離散値 (-1, 0, 1) である場合、適切な結合荷重としきい値を組み合わせ、状態遷移関数にステップ関数を使うことで、論理回路と同様の動きをさせることが可能である。しか

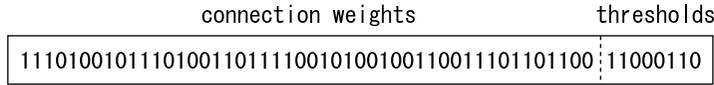


図2 図1に示すFCNの染色体
Fig.2 Chromosome of the FCN shown in Fig.1.

表2 結合荷重・しきい値のコーディングルール
Table 2 Coding rule of connection weights and thresholds.

weight ; threshold	genes
-1	00
0	01 or 10
+1	11

し、FCNは状態遷移にシグモイド関数を採用し、神経素子内部や出力値が連続量を扱えるようにするため、FCNで表現する回路網を論理回路や順路回路だけで構成することはできない。連続量を扱う理由は、たとえば、エージェントの行動制御の際に、距離データのような2値化できない情報を入力値として扱えるようにするためである。

染色体へのコーディング

結合荷重としきい値を一列に並べたものを染色体としてコーディングし、GAにより最適化する。図1の神経回路網は図2により構成される。本論文ではしきい値を結合荷重と同様に±1, 0の3値にし、同様のルールでコーディングした。結合荷重・しきい値と遺伝子との対応は表2に示したとおりである。

一般的に、結合荷重としきい値の学習は構造を決定した後に行われるが、FCNでは構造決定と同時に結合荷重としきい値の学習を行うので構造に縛られない学習となり、高い汎用性が実現できる。

2.2 ユニットの状態遷移方法

ユニットの状態遷移式

図3に示す入出力を持つユニットの状態遷移式は、式(1)に示すようなシグモイド関数を用いる。

$$y_j = \frac{1}{1 + \exp\left\{-\left(\sum_{i=1}^n x_i w_{ij} - \theta_j\right)\right\}} \quad (1)$$

x_i : ユニット i 番の入力

w_{ij} : ユニット i 番からユニット j 番への結合荷重

y_j : ユニット j 番の出力

θ_j : ユニット j 番のしきい値

FCNの動作

全ユニットは入力ユニットから順次伝播してきた信号により、自分自身の信号を出力するものとし、単位時間間隔で同期的に状態遷移を行うものとする。すなわち単位時間あたり1つ分の矢印で表される結合しか信号が伝播しない。

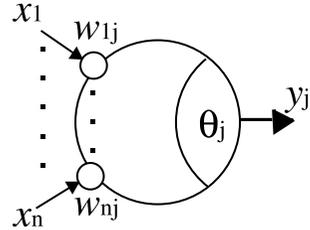


図3 ユニットの入出力
Fig.3 Input and output of a unit.

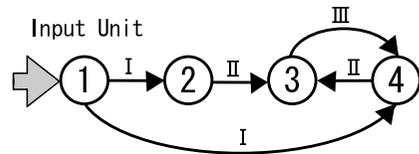


図4 状態遷移の例
Fig.4 State transitions in FCN.

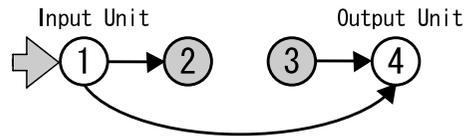


図5 必要のない結合を含む構造
Fig.5 A structure including unnecessary connections.

図4にユニットの状態遷移の例を示す。入力ユニットに信号が初めて入力された時刻を遷移開始 ($t = 0$) とする。

$t=0$: ユニット1(入力ユニット)が結合Iを使い出力開始。

$t=1$: ユニット1が結合Iにより出力。

ユニット2, 4が結合IIを使い出力開始。

$t=2$: ユニット1, 2, 4が結合I, IIにより出力。

ユニット3が結合IIIを使い出力開始。

$t=3$ 以降: ユニット1, 2, 3, 4が結合I, II, IIIにより出力。

枝刈りによる構造の単純化

先に述べたユニットの状態遷移方法を用いると、あるユニット間の結合ではユニットの出力が認められず、その結合が使われない状態が生ずる。FCNではこの必要のない結合を取り除く。また、入力ユニットから伝播した信号が出力ユニットまで伝わらない結合も、不必要と見なし取り除く。

図 5 に例を示す．ユニット 1 は入力ユニット，ユニット 4 は出力ユニットである．ユニット 3 は入力ユニットからの信号が伝播されないため，入力信号に基づく信号出力が不可能である．そのためユニット 3 からユニット 4 への結合はこの神経回路網上では必要がないと考えられる．また入力ユニットからの信号はユニット 2 へは伝播されるが，ユニット 2 からそれ以外のユニットへ伝わることはない．この場合もユニット 1 とユニット 2 の結合が不必要と考えられる．そこで，不要なユニット（図 5 に示す灰色のユニット）とそれらのユニットに関する結合をすべて取り除く．

このような必要のない部分を取り除く操作は染色体から神経回路網を解釈するときに行い，染色体を直接書き換えることはいっさい行わない．これは GA を用いて最適化を進めていった結果，現在は不要である部分が後に有効利用される可能性がないとはいきれないためである．

以上で述べたように，FCN では入力ユニットから伝播された信号を用いてユニットの状態遷移を行うので，得られる結果は神経回路網に入力された信号を反映することができる．

また枝刈りを適用することによって，複雑に絡み合った神経回路網の構造を単純化することができ，必要のない結合を取り除くことで，必要最小限のユニットだけが残ることになる．そのため神経回路網を生成するうえで問題の 1 つとなる，最適なユニット数を調整する作業がある程度軽減されると考えられる．

2.3 FCN に対する最適化の流れ

FCN の最適化には GA を用いる．図 6 に基本的な処理の流れを示す．

本論文での GA の仕様

本論文の実験では，GA の一種である Minimal Generation Gap (MGG ¹¹) を採用した．

- MGG の手順
 - (1) 初期個体集団を発生 (150 個体) .
 - (2) 個体集団から親となる 2 個体をランダムに選択する .
 - (3) 選択した親個体から交叉や突然変異を用いて複数の子個体を作る (今回は 20 個体) .
 - (4) 各個体の適応度を評価する (迷路探索を実行) .
 - (5) 親子合わせた個体群 (家族) から，最良個体を 1 個体選択して個体集団に戻す .
 - (6) さらに，ルーレットルールにより家族から 1 個体を選択して個体集団に戻す .
 - (7) 手順 (2) ~ (6) を 1 ターンとし，終了条件

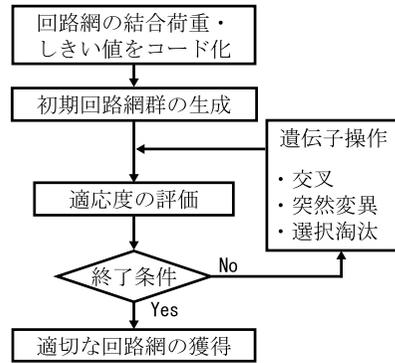


図 6 FCN の最適化の流れ
Fig. 6 Basic procedure of optimization of FCN.

が満たされるまで繰り返す．

- MGG の手順 (5) における最良個体の決定方法
 - Phase1 個体群中の最良な適応度が設定上考えられる最大適応度よりも小さいとき，最良な適応度を獲得している個体を最良個体とする．
 - Phase2 個体群中の最良な適応度が設定上考えられる最大適応度と等しいとき，以下に示す 4 つの指標を 1 から順に優先し最良個体を決定する．
 - 1 最大適応度を獲得している．
 - 2 回路網上で実際に使用するユニット間の結合本数が少ない．
 - 3 回路網上で実際に使用するユニットの個数が少ない．
 - 4 染色体上でのユニット間の結合本数が少ない．
- 交叉

交叉はセグメント交叉を用いた．セグメント交叉を用いることで交叉点数と交叉個所をある程度ランダムに決定し様々な個体を生み出されるようにした．交叉発生率は 100%，セグメント率は 3% とした．
- 突然変異

突然変異は染色体を構成する各ビット単位 (0, 1) で発生する．突然変異が起こるとその染色体のビットはランダムに書き換えられる．突然変異率は 1% とした．

3. 迷路探索問題 (Sutton の迷路)

3.1 Sutton の迷路

提案手法の有効性を確認するために，強化学習の分野において知られている Sutton の迷路^{12),13)}を扱う．図 7 において灰色のマスを壁を表す．迷路内を動き回

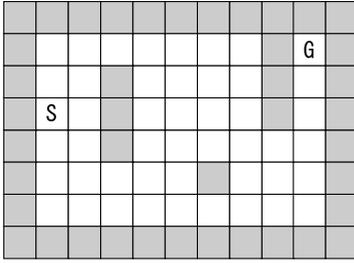


図7 Suttonの迷路
Fig. 7 Sutton's maze.

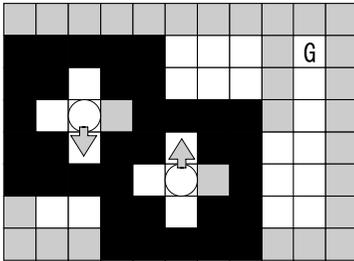


図8 エイリアス問題
Fig. 8 Alias problem.

るエージェントはスタート地点 (S) に配置され、できるだけ少ない歩数 (最短経路) でゴール地点 (G) に到着することが期待される。エージェントは自分の周囲 4 マス (上下左右 (=北南西東)) の壁の有無を知覚することができる。1 回の移動では、上下左右のいずれかに 1 歩だけ進むことができるが、選択した移動方向が壁であった場合は、その場にとどまる。その場合も 1 歩として数える。

3.2 エイリアス問題

エージェントは周囲 4 マスの壁の有無しか知ることができないため、Sutton の迷路ではエイリアスの問題が生ずる。具体的には図 8 に示した 2 つの (エージェント) が記入されている位置のように、エージェントが環境から得る情報は、右側のみ壁が存在するというまったく同一の情報であるが、ゴール地点までの最短経路をたどるためには、それぞれの位置において要求される動作 (矢印方向への移動) が異なるという状況である。ゆえに Sutton の迷路において最短経路を求めるためには、過去の入力を何らかの方法で記憶する仕組みが必要となる。

4. 実験方法

4.1 FCN の初期設定

本実験では入力ユニット 4 個、中間ユニット 7 個、出力ユニット 4 個の計 15 個のユニットを用意した。入力ユニットは No.0 ~ 3、中間ユニットは No.4 ~ 10、

出力ユニットは No.11 ~ 14 と番号を割り振り、入力ユニットにはエージェントの視界左、下、上、右をユニット番号の小さい順に割り当てた。同様に出力ユニットにはエージェントの移動方向左、下、上、右を設定した。これらのユニットからなる神経回路網を FCN の手順により最適化し、Sutton の迷路を探索するエージェントの行動決定実験を行った。

4.2 FCN によるエージェントの行動決定手順

以下にエージェントの行動決定手順を示す。

- (1) エージェントの行動を決定する神経回路網を個体 (FCN) から作る。
- (2) エージェントをスタート地点に配置。
- (3) エージェントの周囲 (上下左右) の壁の有無を調べ、壁が存在する状態を 0.9、存在しない状態を 0.1 で表現し、対応する入力ユニットにそれぞれ入力する。
- (4) 状態遷移を行い、各ユニットの出力値を計算する。
- (5) 4 つの出力ユニットの中で最高出力値を持つユニットの設定方向をエージェントの移動方向とする。ただし、最高値を出力したユニットが複数存在した場合は考慮し、移動方向の決定には優先度を設定する。
- (6) FCN の結果に従いエージェントを移動させる。
- (7) エージェントがゴールに到着。もしくは、エージェントの移動回数が 21 回を超えた場合は終了。そうでなければ手順 (3) に戻る。

Sutton の迷路における最短経路は 6 通り存在し、どの経路もスタートからゴールまで左に 0 回、下に 2 回、上に 4 回、右に 8 回の計 14 回移動する必要がある。つまり、移動方向の優先度は右、上、下、左である。今回、移動方向決定の優先度は、あえて必要移動回数とは逆の順位設定とした。つまり左、下、上、右の順に優先される。予備実験としてこの優先順位の全パターンを試行した結果、移動方向の優先度は、獲得された最短経路の種類に多少の影響を与えた。しかし最短歩数でゴールするという今回の目的に対しては何ら問題がなかった。また、移動機会の最大数は 21 回とした。移動機会を最短歩数よりも余分に設定することで、エージェントの探索領域は広がることになる。

4.3 適応度の定義

本実験では FCN に基づいて行動決定したエージェントの迷路探索の結果を適応度として扱った。Sutton の迷路内に図 9 で示すような分布の適応度を設定した。エージェントが 1 回の探索において最終的にたどり着いた位置に記されていた値をその個体の適応度

	2	3	4	5	6	7	8		G	
	1	2		6	7	8	9		13	
	0	1		7	8	9	10		12	
	1	2		6	7	8	9	10	11	
	2	3	4	5	6		8	9	10	
	3	4	5	4	5	6	7	8	9	

図9 適応度分布

Fig. 9 Distribution of fitness values.

とした。つまりゴールまでの最短経路上となる位置ではゴールへ近づくほど適応度が高くなり、最短経路を外れると適応度が低くなるようになっている。なお、エージェントをゴールに到着させることができた個体には、図9で示した値ではなく、式(2)で算出される適応度を与えた。

$$f = c + m - s \tag{2}$$

f : 適応度

c : 移動機会数

m : スタート地点からゴール地点までの最短経路を移動する最短歩数

s : ゴール到着時の移動歩数

この式は、より少ない歩数でエージェントをゴールに到着させた個体ほど高い適応度が得られるように配慮した式である。式(2)に基づく、Suttonの迷路のための適応度計算式は、 $c = 21$ 、 $m = 14$ なので式(3)のようになる。

$$f = 35 - s \tag{3}$$

Suttonの迷路での最短歩数は14歩なので、最大適応度は21となる。ただし、迷路中に描かれた適応度の値は、GAにおいて個体を評価する際に用いる値であり、迷路内での探索終了(ゴール到着もしくは21回の移動)後に適応度を与えるため、個体および迷路を動き回るエージェントは、図9の適応度分布をいっさい知ることができない。

5. 実験結果と考察

5.1 全体の結果

FCNを用いてSuttonの迷路を解くための試行を20回行った結果、全試行において最短経路を獲得することに成功した。最大適応度への到達に要した時間およびターン回数はそれぞれ次のとおりである。ただし、使用した機材はPentium 4プロセッサ 2.2GHzである。

平均時間 : 0.75 秒

平均ターン : 380.2 回

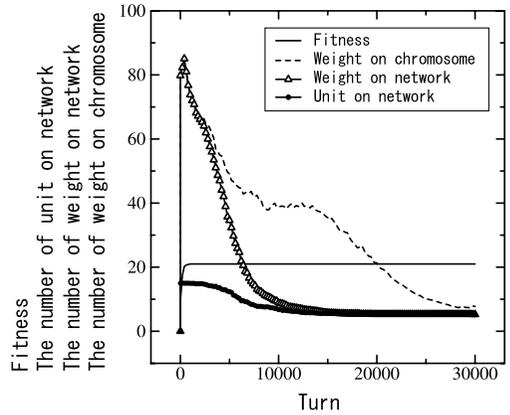


図10 最良個体の各要素の変遷(20試行の平均)

Fig. 10 Transition of each element of the best individual (Average of 20 trials).

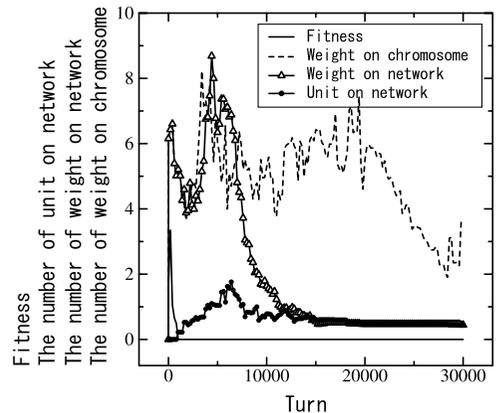


図11 最良個体の各要素の変遷(20試行の標準偏差)

Fig. 11 Transition of each element of the best individual (Standard deviation of 20 trials).

最良個体の各要素の変遷

ターンによる最良個体の各要素の変遷を、図10、図11の20試行の平均と標準偏差によって示す。これらの図より必要なユニットや結合を獲得し、必要のない部分が省かれていく様子が観察できる。

最短経路の獲得状況

Suttonの迷路は最短経路が6種類存在する。各経路は図12に示したとおりである。Suttonの迷路における20回の試行の結果、最適化過程において最大で6種類、すべての最短経路を獲得していた個体集団も存在していたことを確認した。しかし今回の実験では、複数の解答を持つ問題に対して、それらすべてを獲得するには設定せず、構造の単純なものが獲得できるように最適化を進めたため、route1を通過する個体が多く得られた。



図 15 下方向移動決定

Fig. 15 Structure to move down direction.

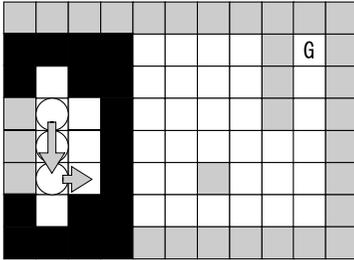


図 16 エイリアス (1)

Fig. 16 Alias (1).

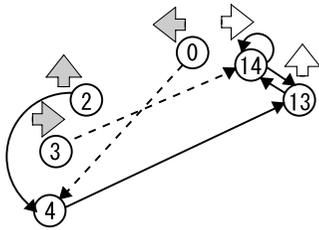


図 17 上・右方向移動決定

Fig. 17 Structure to move up or right direction.

下方向移動決定とエイリアス

次に図 15 は下方向の移動を決定するための構造である．下方向移動決定ユニット No.12 への信号入力は視界の右方向 (ユニット No.3) からの伝播のみによって決定されている．ここで図 16 に示されたエイリアスについて考える．図 16 は最初の 2 歩までは下方向の移動であるが，3 歩目は右に進む．表 3 より下方向を決定するユニット No.12 はほぼ一定の値となり，この値を超えた出力値を持つ出力ユニットが選択方向として使われていることから，出力ユニット全体の基準値としての働きがあると考えられる．ゆえに，3 歩目で移動方向が変わったのはこのためである．

上・右方向移動決定とエイリアス

図 17 は上および右への移動を決定するための構造である．上方向移動決定ユニット No.13，右方向移動決定ユニット No.14 はともに，自己ループやユニット間ループによる入力や，遅延の役割をするユニットが存在する．これらの部分は，神経回路網の過去の内部状態を履歴として蓄える働きを持つため，上，右方向への移動の決定には過去のエージェントの視野や動作が大きく作用してくるものと考えられる．図 18 では 4, 6, 8, 10 歩目がエイリアスである．6 歩目のみが上

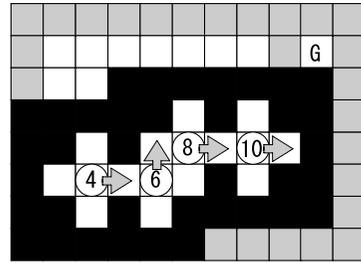


図 18 エイリアス (2)

Fig. 18 Alias (2).

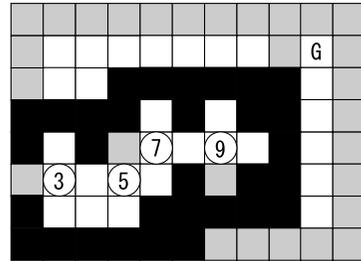


図 19 3, 5, 7, 9 歩目のエージェントの位置

Fig. 19 3, 5, 7, 9 steps of the agent position.

方向へと移動し，他では右方向へ移動している．ここで図 17 を参照すると，上方向の視野が対応しているユニット No.2 から入った信号はユニット No.4 を通って，1 ステップ遅れて上方向移動決定ユニット No.13 に入力されている．図 19 に，図 18 で示した各エイリアスが発生する状況のそれぞれ 1 歩前の状況を示す．つまり，3, 5, 7, 9 歩目でエージェントの位置である．

5 歩目に注目すると，他の 3, 7, 9 歩目とは違い，エージェントの上方向に壁が存在している．この壁が存在しているという信号が次の移動のときにユニット No.13 に伝わり，結果として図 18 のようなエージェントの動きの違いを生じさせたものと考えられる．

5.3 追加実験

追加実験として，図 20 に示すような Sutton の迷路よりもエイリアスの発生回数が多く難易度の高い迷路にも FCN を適用した．その結果，すべての迷路に対して最短経路を獲得することに成功した．

6. ま と め

本論文では，問題の内容や性質に関係なく，求められている神経回路網を構成，獲得するための手法として FCN を提案した．その有効性を示すためにエイリアスを含む迷路探索問題を設定し実験を行った．実験の結果をまとめると次のようになる．

- エイリアスの発生数や性質の異なる問題を含む迷

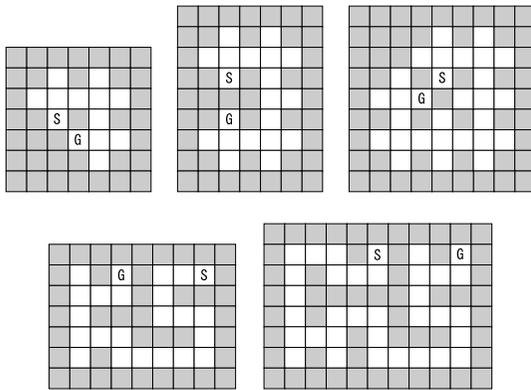


図 20 その他の迷路
Fig. 20 Other mazes.

路に対して実験を行った結果、それらすべてに対して適切な神経回路網を獲得することに成功した。

- 獲得された神経回路網は、進化の過程で必要なユニットや結合を適切に選択、獲得していった。このことは、今後さらに複雑な問題へも対処できる可能性を示している。

今後の課題として考えられるものを次に示す。

- タスクの複雑さにともないユニット数や結合本数が増加し、最適化に必要な時間が非常に長くなることが予想される。このようなスケール問題への対応として、たとえば次に示すように、最適化する染色体の形状や GA の方法論自体への工夫が必要であると考えられる。
 - 局所解での突然変異の発生頻度の工夫
 - 神経回路網の構造を活かした交叉方法の改良
- 本方式では、中間ユニットの個数を経験的に入力ユニットの 2~3 倍程度に設定している。中間ユニットが与えられた問題を解くために必要な個数よりも多い場合、本方式により適切な個数のユニットが選択される。しかし余分なユニットを用意することによって最適化に要する計算時間が増えるため、進化的に中間ユニットの個数を増加させ適切な個数を自動獲得することで、人が介入する部分を省き、同時に最適化速度の向上を目指す必要がある。
- 本論文では、エイリアスに適切に対処できる神経回路網の獲得を目指しその検証を行った。しかし特定の迷路という条件下で実験を行ったため、頑健性への検討を本論文で行うことはできない。そこでタスク変化が生ずる問題に本手法を適応し頑健性の検証を行う必要がある。
- 任意構造の神経回路網が獲得できることから、ヤ

リカのような生物の比較的単純な神経系の推定への適応の検討を行う。

なお、本論文の問題設定ではエージェントの最終的な到達場所に応じて異なる評価値（適応度）を与えているため、ゴール到着時のみに評価値を与える問題に対して比較的容易であると考えられる。そのため、今後はより難易度の高い問題に本手法を適応しその有効性を明確に示す予定である。

参考文献

- 1) 麻生英樹：ニューラルネットワーク情報処理，産業図書（1988）。
- 2) 長尾智晴，安居院猛，長橋 宏：遺伝的手法による神経回路網の構造進化，電子情報通信学会論文誌 D-II，Vol.J75-D-II，No.9，pp.1634-1637（1992）。
- 3) 長尾智晴，安居院猛，長橋 宏：GA による仮想生物の運動制御用神経回路網の自動生成，電子情報通信学会論文誌 D-II，Vol.J78-D-II，No.7，pp.1150-1152（1995）。
- 4) 高橋裕樹，中嶋正之：遺伝的アルゴリズムを用いた最適な階層構造神経回路網の構造決定に関する一考察，電子情報通信学会論文誌 D-II，Vol.J79-D-II，No.11，pp.1920-1928（1996）。
- 5) de Garis, H.: Genetic programming: building artificial nervous systems using genetically programmed neural network modules, *Machine Learning: Proc. 7th International Conference*, pp.132-139（1990）。
- 6) Montana, D. and Davis, L.: Training Feed-forward Neural Networks Using Genetic Algorithm, *Proc. 11th International Joint Conference on Artificial Intelligence*, pp.762-767（1989）。
- 7) Whitley, D. and Hanson, T.: Optimizing Neural Networks Using Faster, More Accurate Genetic Search, *Proc. 3rd International Conference on Genetic Algorithm*, pp.391-396（1989）。
- 8) Kitano, H.: Designing Neural Networks Using Genetic Algorithm with Graph Generation System, *Complex System*, Vol.4, No.4, pp.461-476（1990）。
- 9) Ono, I.M. and Takahashi, N.O.: Evolving Neural Networks in Environments with Delayed Rewards by A Real-Coded GA using the Unimodal Normal Distribution Crossover, *Proc. 2000 Congress on Evolutionary Computation*, pp.659-666（2000）。
- 10) Moon, S.W. and Kong, S.G.: Block-Based Neural Networks, *IEEE Trans. Neural Networks*, Vol.12, No.2, pp.307-317（2001）。
- 11) 佐藤 浩，小野 功，小林重信：遺伝的アルゴ

リズムにおける世代交代モデルの提案と評価, 人工知能学会誌, Vol.12, No.5, pp.734-744 (1997).

- 12) Sutton, R.S.: Integrated architectures for learning, planning, and reacting based on approximating dynamic programming, *Proc. 7th International Conference on Machine Learning*, pp.216-224 (1990).
- 13) McCallum, R.A.: Overcoming Incomplete Perception with Utile Distinction Memory, *Proc. 10th International Conference on Machine Learning*, pp.190-196 (1993).

(平成 15 年 2 月 10 日受付)

(平成 16 年 1 月 6 日採録)



田澤 和子

1978 年生. 2002 年横浜国立大学工学部電子情報工学科卒業. 同年同大学大学院環境情報学府情報メディア環境学専攻情報メディア学コース入学. 神経回路網を用いたエージェント制御に関する研究に従事. 電気学会学生会員.



長尾 智晴 (正会員)

1959 年生. 1985 年東京工業大学大学院博士後期課程中退. 同年同大学工学部附属像情報工学研究施設助手. 同大学工学部助教授を経て, 2001 年横浜国立大学大学院環境情報研究院教授, 現在に至る. 工学博士. 画像工学, 進化的計算法, 神経回路網, マルチエージェント, 進化経済学等に関する研究に従事. 著書『進化的画像処理』(昭晃堂)等. 電子情報通信学会, 人工知能学会, 計測自動制御学会, 進化経済学会, 映像情報メディア学会, IEEE 等会員.