

ナビゲーション問題におけるエージェントの行動獲得への進化的アプローチ

○函館高専 石若 裕子, 浜 克巳, 札幌学院大 皆川 雅章, 北大 嘉数 侑昇

要旨

エージェントの行動獲得を目的としたコンストラクティブなリカレント型ニューラルネットワークを構築し、迷路問題に適用した。最小のネットワークを得るために一手法として、Recurrent Cascade Correlation(RCC)を実現した。ネットワークの学習方法として進化プログラミング(EP)と遺伝的アルゴリズム(GA)を用いて、簡単な迷路について実験を行い、この方式における行動獲得能力について検討した。

緒言

本研究は、ナビゲーション問題として最短経路を求める迷路問題をとりあげ、エージェントの行動獲得能力について調査することを目的としている。具体的には、最小のネットワークで最適解が求められるように、コンストラクティブなリカレント型ニューラルネットワークである Recurrent Cascade Correlation(RCC)^{[1][2]}を実現し、学習方法として進化プログラミング(EP)と遺伝的アルゴリズム(GA)を採用した。

問題空間の記述

ここで扱うナビゲーション問題は、ある探索空間に存在するエージェントが出発点から目的地まで達するための経路を求めるというものである。対象問題は以下のように表現される。

$$P = (S, ag^t, ps, pg, M) \quad (1)$$

ここで

- S : 対象空間
- $S = \{(x, y, b) | x \in X, y \in Y, b \in B\}$
- $X = \{1, 2, \dots, M\}, Y = \{1, 2, \dots, N\}, B = \{0, 1\}$
- 0: 障害物
- 1: 通行可能
- ag^t : エージェントの時刻 t における状態
- ps : スタート位置
- pg : ゴール位置
- M : 行動結果

である。エージェントは現在位置の情報および前後左右の障害物の情報を得ることができ、1ステップにつき前後左右のいずれかに1座標だけ移動可能である。

$$ag^t = (x^t, y^t) \quad x \in N, y \in M, t \in T \quad (2)$$

$$ag^{t+1} = \delta(ag^t, a) \quad (3)$$

$$a \in A, A = \{\text{forward, backward, left, right}\}$$

エージェントはスタート地点の座標の情報を持っているが、ゴール地点の情報は持っていない。そのためゴール地点に達するまで、現在位置が目的地であるかどうかは判定できない。スタート状態、ゴールに達成した状態を次のように表す。

ここでは、エージェントができるだけ少ないステップ数で出発地から目的地までの経路を求ることを目指す。

的とする。

$$\begin{aligned} findM &= \{m | \delta(ag^0, m) = ag^G\} \\ ag^0 &= PS, ag^G = PG \\ m &= a_1 a_2 \cdots a_n, \quad a_j \in A \end{aligned} \quad (4)$$

方法論

ある迷路を探索し、最短距離を求めるための最小のネットワークを構築する手法として、コンストラクティブなリカレント型ニューラルネットワークである RCC を用いた。RCC は入力ユニット、出力ユニット一つの中間ユニットからなる単純なネットワークに対して、最適解が求まるまで中間ユニットを一つずつ付け加えることによって、ネットワークを構築していく(Fig.1)。ナビゲーション問題に対応させるために、教師なしとし、かわりに評価関数を用いた。学習アルゴリズムは EP および GA とした。以下に今回用いた計算手順を簡単に示す。

1. Fig.1 のネットワークにおいて、出力ユニットに関するすべての荷重(W^{yx}, W^{yu})を学習させる。
2. 最適解が求まらなければ、優秀な中間ユニットを加えるために、Candidate ユニットと呼ばれる中間ユニットの候補群を用意し、中間ユニットに関するすべての荷重(W^{xc}, W^{cu}, W^{xca})を学習させる。このとき、1.のネットと違い
 - ・Candidate ユニットと出力ユニットのリンクはない
 - ・Candidate ユニットは、それぞれ入力ユニットとすべての存在する中間ユニットと結合している
 - というネットにおいて学習を繰り返す。
3. Candidate ユニットのなかで最も優秀なものをネットに加え、新しい中間ユニットから出力ユニットへのリンクを発生させる。
4. 最適解が求まるまで、以上の作業を繰り返す。

式(5)に Candidate ユニットを付加したネットワーク構造の式を示す。

$$\begin{aligned} X(k) &= W^{xc} X(k) + W^{xu} U(k-1) + W^{ca} X^{ca} \\ X^c(k) &= \alpha X(k-1) + \alpha X^{ca} \\ Y(k) &= W^{yx} X(k) + W^{yu} U(k) \end{aligned} \quad (5)$$

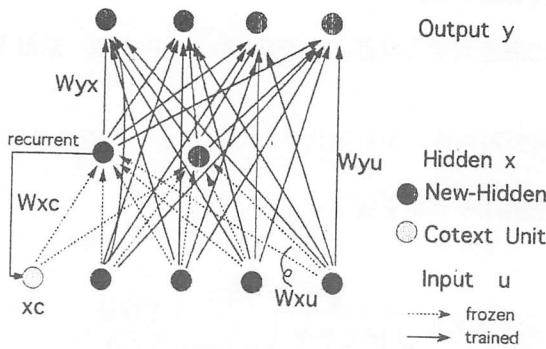


Fig1. Network Architecture for Cascade Correlation

ここで、 w は Weight Matrix である。出力を[0,1]に収めるために、出力関数

$$Out_i = \frac{1}{1 + \exp(-S_i)} \quad (S_i = \sum_j w_{ji} u_j) \quad (6)$$

を用いた。各エージェントの達成度の評価は次式によつて与えられる。

$$F_i = \frac{E_{\max} - E_i}{E_{\max}} \quad (7)$$

ここで、 E_{\max} は最大ステップ数、 E_i は各エージェントのステップ数とする。ゴールに全く辿り着かないときは、ステップ数が最大になったとき、スタートから遠い位置にいたものを優秀なものとした。

EPによる結合荷重の変化は以下の式による。ここで、 N は正規分布を表す。

$$w = w + c \cdot N(\mu, \sigma^2) \quad (8)$$

$$c = \begin{cases} 1 - F: success \\ 1: failure \end{cases} \quad (9)$$

GAによる交差は福田^[6]らの方法を用いた。ここでの詳しい説明は省く。

実験

実験はスタートからゴールまで辿り着く経路が二つある小規模な迷路に対して行った。Fig2 に示した経路は、RCC によって構築されたネットワークにおいて最適解が求まった中間ユニット数(EP5, GA6)での荷重を入力したときの探索結果である。比較のために Modified Elman Network を用いたときの探索結果も同図に示した。学習アルゴリズムはそれぞれ EP, GA の二通りについて行った。Fig.3 に適応度と世代数の関係の結果図を、表 1 に実験に用いたパラメータを示す。

実験結果より、RCC を用いた場合、EP, GA ともに最小ステップ数でゴールに到達している。Modified Elman Network を用いた場合の中間ユニット数と比較しても、RCC の方がより少ない数で最適解が求まっている。Modified Elman Network は最短経路を求ることはできたが、途中にループが入り、最小ステップ数とはなっていない。これは、設定した中間ユニット数が対象となる迷路に対して多すぎ、冗長になっていると考えられる。学習アルゴリズムによる差が見られないのは、迷路が小規模であるためであると思われる。

Table 1

	Cascade Correlation	Modified Elman Network
Generation	60	100
Individual	60	100
Pool of Candidate unit	60	---
Hidden units	Incremental	9
μ, σ (EP)	0, 1	0, 1
Mutation(GA)	10%	10%

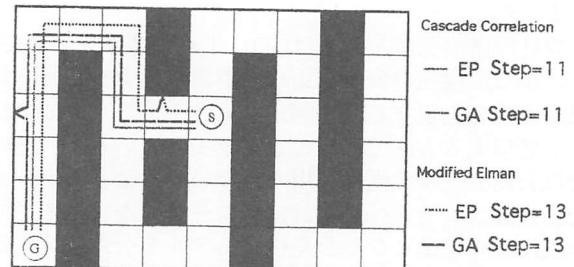


Fig2. Maze

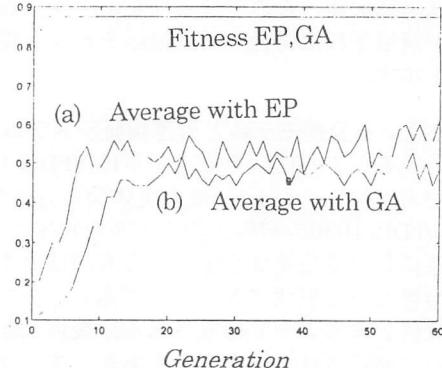


Fig3. The Transition of Fitness with Cascade Correlation (a)EP(hidden unit 5) (b)GA(hidden unit6)

結言と今後の課題

リカレント型ネットワークを動的に構築していく方法として、Recurrent Cascade Correlation を採用し、迷路の最短経路を求める問題に対して実験を行った。その結果、今回用いた迷路では、中間ユニット数を固定したネットワークでは求めることができなかった最適解が、RCC を用いることによって、より少ない中間ユニット数で求めることができた。今後の課題として、評価関数の検討、および複雑な迷路や動的環境に対しての探索能力の調査をする必要がある。

参考文献

- Markus Hoehfeld and Scott E. Fahlman : Learning with Limited Numerical Precision Using the Cascade-Correlation Algorithm, IEEE TRANSACTIONS ON NEURAL NETWORKS, Vol 3, No 4, July, 1992
- Scott E. Fahlman : The Recurrent Cascade-Correlation Architecture, CMU-C3-91-100, May 17, 1991
- P. J. Angeline, G. M. Saunders, and J. B. Pollack : An Evolutionary Algorithm that Constructs recurrent Neural Networks, IEEE, NN, Vol 5, 1995
- 皆川、嘉数：マルチエージェントの協調による積木問題へのアプローチ、機論、投稿中
- 川上、嘉数：クラシファイアーシステムによる自律型ロボットナビゲーション問題に関する研究、機論 C, 59-564, 1993
- 福田、河野、柴田：リカレントニューラルネットワークの遺伝アルゴリズムによる学習、機論 C, 59-564, August, 1993