

進化的スパイクングニューラルネットワークを用いた エージェントの向きの学習

The direction learning of an agent with evolutionary spiking neural network

○田内 洋吉 (大阪大学) 畠中 利治 (大阪大学)

Hiroyoshi TANOUCHI, Osaka University, h-tanouchi@ist.osaka-u.ac.jp
Toshiharu HATANAKA, Osaka University, hatanaka@ist.osaka-u.ac.jp

A neuroevolution is a kind of learning algorithms for an artificial neural networks by using an evolutionary computation methodology. In this paper, we consider a neuroevolution of a spiking neural network. We deal with a simple task that an agent turns to sequentially specified positions from its original position. The spike response model is employed as a neuron model, then a three layered network is evolved to perform a task, by a real coded genetic algorithm with blend crossover. Some numerical examples are presented to show the availability of GA in spiking neural network evolution.

Key Words: Genetic Algorithm, Spiking Neural Network, Neuroevolution.

1. はじめに

遺伝的アルゴリズムなどの進化計算を用いたニューラルネットワークの学習を Neuroevolution といい、ある環境下におけるエージェントの行動に対する評価を適応度とし、遺伝的操作と淘汰の作用によって、エージェントの動作を与える内部のニューラルネットワークをよりその環境とタスクに適したものへと変化させていく方法を与えるものである。特に、ネットワークの結合係数だけでなく、構造を同時に進化させていく NEAT[1]などがよく知られている。その多くで、ニューロンには非線形応答素子が採用され、出力の大きさがネットワークを介して他の素子に伝達されるモデルが採用されている。しかしながら、実際の生物の神経系では、スパイクが情報の伝達を担っている。このため、スパイク型のニューラルネットワークモデルの研究は数多くなされているが、スパイクングニューラルネットワークを対象にした Neuroevolution に関する研究はあまり多くない。そこで、我々は、スパイクングニューラルネットワークに対する Neuroevolution についての検討を始めている。本発表では、T.M.Poulsen and R.K.Moore が提案した、エージェントに刻々その向きを 18 度ずつ時計回りに回転させるというタスク[2]に対するスパイクングニューラルネットワークの進化に関しての基本的な検討を行ったので、その結果を紹介する。

2. ニューロンモデル

本研究では、ニューロンモデルは[2]に準じて式(1)で表されるスパイクレスポンスモデル (SRM) を用いる。

$$u_i(t) = \sum_{l_i^f \in F} \eta(t-t_i^f) + \sum_j w_j \sum_{l_j^f \in F} \varepsilon_{ij}(t-t_j^f) \quad (1)$$

i はシナプス後細胞、 j はシナプス前細胞を表す。また、 w_j は synaptic efficacy、 t は現在時刻、 t^f はニューロンの f 回目の発火時刻を表す。ニューロンは u が閾値 u_{thresh} を超えたとき発火する。 η は

$$\eta(s) = -(u_{thresh} - u_{rest}) e^{-\frac{s}{\tau_{ref}}} \quad (2)$$

で表される。 $s = t - t^f$ であり u_{rest} は静止電位、 τ_{ref} は、発火後にニューロンが静止電位に戻るまでに要する時間を決める時

定数である。 ε は

$$\varepsilon(s) = e^{-\frac{s-\Delta_{abs}}{\tau_m}} (1 - e^{-\frac{s-\Delta_{abs}}{\tau_s}}) \Theta(s - \Delta_{abs}) \quad (3)$$

で表される。 Δ_{abs} は他のニューロンで発生したスパイクが到達するのに要する時間を表し、 τ_m と τ_s は、それぞれニューロンの膜とシナプス結合の特性を表す時定数である。また、 Θ はヘビサイドの階段関数である。

3. エージェントのネットワーク

エージェントの動作を与えるニューラルネットワークは、文献[2]に準じて 18 個のニューロンを用いて構成され、中間層ニューロン同士がリカレント結合をしている 3 層のネットワークとした。このネットワークを実数値 GA を用いて変化させ、与えられたタスクでより良い結果を出せるネットワークへ進化させていく。後述するタスクでは、出力ニューロンを 2 つのタイプ (右出力, 左出力) に分け、同じタイプのニューロンの合計発火回数をエージェントの回転角度の決定に用いる。そのため、ニューロンには、入力, 中間, 右出力, 左出力の 4 つのタイプが存在する。

GA における個体の染色体表現を説明するため、まず、1 つのニューロンの遺伝子について説明する。 w_j , Δ_{abs} , τ_s の大きさに対応する各遺伝子は他のニューロンに対して 1 組ずつ用意され、ニューロン自身の特性を表す τ_m , τ_{ref} は各々 1 個である。さらに、ニューロン自身のタイプを表す遺伝子が 1 個存在する。よって、1 つのニューロンの遺伝子は、18 個のニューロンからなるネットワークでは 54 個存在し、ネットワーク全体を表す染色体は 972 個の遺伝子で構成される。Fig.1 に染色体の構成を示す。

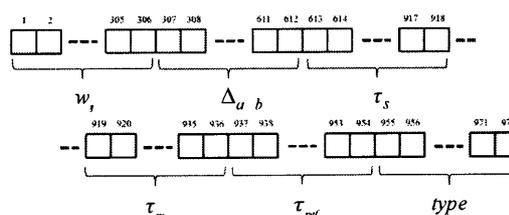


Fig.1 Agent genome

4. シミュレーション

4.1 タスク

ここでは、2つの車輪を持つエージェントを考える。エージェントのタスクは、両車輪の回転差により、100ms 毎に移動せずに回転のみを行い、エージェントを原点とする半径 30m の円周上の1点（以下、source と呼ぶ）に向くというものである。source は、0°から円周上を反時計回りに18°ずつ移動していく。回転は連続で20回行う。ただし、エージェントは毎回90°を向いた状態から回転を開始する。タスクの概略を Fig.2 に示す。各円の中心にある四角がエージェントを、各円周上の点が source を表している。各回におけるエージェントの回転角度は、100ms 間の全右出力ニューロンの発火回数 n_r と全左出力ニューロンの発火回数 n_l によって式(4)の a となる。つまり、 $n_l > n_r$ であれば左車輪が右車輪よりも多く回転し右回転、その逆であれば左回転となる。

$$n_l > n_r : a = 2\pi\left(\frac{n_r}{n_l} - 1\right) \quad , \quad n_l < n_r : a = 2\pi\left(1 - \frac{n_l}{n_r}\right) \quad (4)$$

このタスクでは外部からの入力はなく、最初の 100ms 間に入力ニューロンが各々10回発火する。

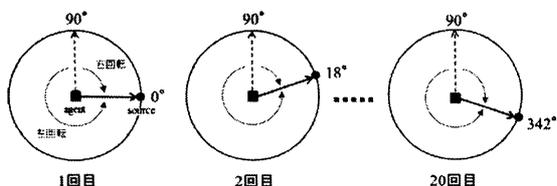


Fig.2 Agent task

4.2 評価方法

エージェントから、その正面方向に 1m 離れた点を考える。この点と source との距離を d_{point} 、エージェントと source との距離を d_{agent} とする。エージェントが回転動作を行った場合は、式(5)の d_{diff} を求め、それを式(6)の v （初期値 0）に加えるか、 v から引く。どの出力ニューロンも発火せず回転動作を行わなかった場合は、 v から 1 を引く。最後に v を 20 で割り、その値をエージェントの適応度 f とする[2]。

$$d_{diff} = (d_{agent} - d_{point})^{28} \quad (5)$$

$$v = \begin{cases} v + d_{diff} & (d_{point} < d_{agent}) \\ v - d_{diff} & (d_{point} > d_{agent}) \\ v - 1 & (n_r = n_l = 0) \end{cases} \quad (6)$$

$$f = v / 20 \quad (7)$$

4.3 遺伝的アルゴリズム

親の選択にはルーレット選択を用いる。交叉確率は 0.8 とし、交叉方法には BLX- α [3]を用いる。突然変異の確率は 0.2 とし、その内 95%では摂動を与え、残りはランダムな値への変更を行う。親個体から子個体を 100 体作り、評価する。そして、親個体と子個体の中から適応度の高い 100 体を次の世代の個体とする。世代数は 3000 としてシミュレーションを行う。 w_i , Δ_{abs} , τ_s , τ_m , τ_{ref} の取り得る値の範囲を Table.1 に示す。ニューロンのタイプについては、 $type$ の値が 0.1~10.0 のニューロンを入力、10.1~20.0 を中間、20.1~30.0 を右出力、30.1~40.0 を左出力とした。

Table.1 Range of parameter value

Parameter	Min	Max
w	-1.0	1.0
Δ_{abs}	0.1	60.0
τ_s	0.1	60.0
τ_m	2.0	60.0
τ_{ref}	0.1	50.0
$type$	0.1	40.0

4.4 結果

40 回の異なるシミュレーションを行った。各シミュレーションで得られた最大の適合度を持つエージェントを比較すると、適合度の最大は 0.97、最少は 0.39 であり、平均適合度は 0.68 となった。最も適応度の高いエージェント ($f \approx 0.97$) が得られたシミュレーションにおける適応度の変化を Fig.3 に示す。

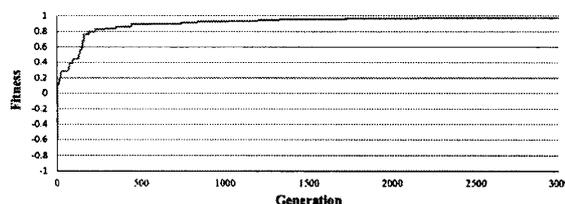
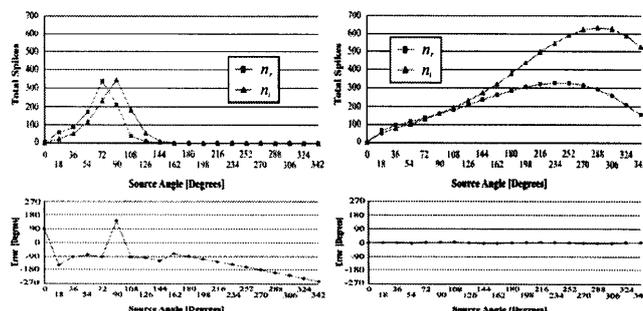


Fig. 3 Fitness

さらに、そのシミュレーションの初期世代で最大適合度を持つ個体と全世代で最大適合度を持つ個体について、タスクでの n_r , n_l と角度の誤差の変化を Fig.4 に示す。



初期世代の最良個体 全世代の最良個体
Fig.4 Sequence of n_r , n_l and error

5. おわりに

エージェントを刻々所定の向きに回転させるタスクを対象に、スパイクングニューラルネットワークに対する Neuroevolution の検討を行った。ニューロンタイプのインデックスと各種のパラメータからなる高次元の設計変数空間における連続変数の調整問題として定式化され、実数値 GA による性能評価実験を行った。紙面の関係で一部の結果のみを紹介したが、詳細な実験結果については発表の際に示す。

文献

- [1] Stanley, K. O. and Miikkulainen, R., "Evolving neural networks through augmenting topologies," Technical Report, AI2001-290, Department of Computer Sciences, The University of Texas, 2001.
- [2] Poulsen, T. M. and Moore, R. K., "Evolving Spiking Neural Parameters for Behavioral Sequences," LNCS, vol. 5769, pp.784-793, 2009.
- [3] Eshelman, L.J. and Schaffer, J.D., "Real-coded genetic algorithms and interval-schemata," Foundations of Genetic Algorithms, vol.2. Morgan Kaufman, San Francisco, 1993.