

スパイクニューラルネットワークによる行動パターンの学習と推定

日大生産工 ○梅原 功平 日大生産工 山内 ゆかり

1 まえがき

近年、人工知能の分野において人間の脳内の神経細胞の繋がりを模した、ニューラルネットワークの研究は盛んに行われてきたが、そのニューロンモデルは工学的応用において有用な性質の一部のみを用いて単純化し、設計されているものだった。しかし、実際の脳内のニューロンの応答特性はより複雑なものであった。

パルスニューロンモデルは、パルス入力による神経細胞の内部状態の変化を実際の生体反応に近い形で模式化するものであり、一般的な積分器型のモデルよりも詳細な手法である。従来のニューロンモデルの多くは、スパイクの時間平均によって情報を表現しており、一つ一つのスパイクには大きな意味がないものとしていた。一方、パルスニューロンモデルでは一つのスパイクの有無や発火のタイミングに着目し、それらに応じてネットワークの振る舞いに変化するようなモデルを構成することが可能となる。スパイクニューラルネットワークはパルスニューロンモデルに基づいたニューラルネットワークの一種であり、時系列処理能力に優れた学習モデルである。

大保氏らは、スパイクニューラルネットワークにおけるスパイク応答モデルを単純化し、更にネットワークの構造を下位層、上位層に分け、これらを短期記憶と長期記憶に見立てて学習を行うモデルを提案した。(1)

本研究では、大保氏らの手法を元にした、単純化されたスパイクニューラルネットワークを構築し、エージェントの行動の時系列パターンを学習する。

2 従来研究

大保氏らによる従来の研究では、スパイクニューラルネットワークを単純化したモデルである、Spike Response Modelを使用してい

た。このモデルにおいて、 i 番目のニューロンの内部状態を表す内部電位を $h_i(t)$ とすると(1)式のように計算される。

$$h_i(t) = \tanh(h_i^{syn}(t) + h_i^{ext}(t) + h_i^{ref}(t)) \quad (1)$$

ここで、 $h_i^{ext}(t)$ は外部からの入力値を示し、 $h_i^{syn}(t)$ はニューロンの内部状態と入力に基づき更新する値、 $h_i^{ref}(t)$ は不応期の値をそれぞれ示す。 $h_i^{syn}(t)$ は、次の(2)式で求められる。

$$h_i^{syn}(t) = \gamma^{syn} h_i(t-1) + \sum_{j=1}^N w_{j,i} h_j^{PSP}(t-1) \quad (2)$$

ここで $w_{j,i}$ は i 番目から j 番目のニューロンへの結合強度、 $h_j^{PSP}(t)$ は離散時間 t における j 番目のニューロンからのシナプス後電位を示す。また、 N はニューロンの総数、 γ^{syn} は減衰項を示す。

$h_i^{ref}(t)$ は、次の(3)式のように計算される。

$$h_i^{ref}(t) = \begin{cases} \gamma^{ref} h_i^{ref}(t-1) - R & \text{if } p_i(t-1) = 1_i \\ \gamma^{ref} h_i^{ref}(t-1) & \text{otherwise} \end{cases} \quad (3)$$

これらの従来研究では、複雑な発火パターンに対応できない、学習されたパターンへの意味付けが行われていないなどの問題点が存在していた。

3 提案手法

本研究では、従来研究を元にした SpikeProp モデルを用いて学習を行う。

また、従来研究では行動パターンを学習しても、そこに意味づけが出来ていない等の問題が存在していたため、本研究では、学習されたパ

Learning and Estimation of Agent Behavior by Spiking Neural Network

Kouhei UMEHARA and Yukari YAMAUCHI

ターンを利用して、エージェントの行動に利用する。各ニューロンの内部電位の計算には(1)式を使用する。更に、エージェントの位置を各センサーとの距離で管理し、それらを教師信号として与え、学習させる。

4 実験環境および実験方法

本研究では、仮想的空間となるマップを用意し、ある規則に従ってエージェントにマップ内を移動させ、その移動の情報をニューロンへの入力とする。図1に実験環境を示す。




図1.実験環境

図1では、マップ上に存在している赤い点がエージェントであり、このエージェントがマップ内を移動する。また、マップの左下、右上、右下にはそれぞれエージェントとの距離を観測するセンサー(S0,S1,S2)が存在しており、これらを入力とし、内部電位の変化を測定する。

5 実験結果および検討

本実験の学習結果を図2に示す。




図2.実験環境

図2では、実験環境の様子を示している。それぞれのセンサーからの距離を計算し、それを元に内部電位の計算を行う。それぞれのセンサー距離を表示し、また画面下部にはそれぞれの内部電位を表示し、その下には不応期の数値も表示している。

本図において、学習ごとに内部電位が更新されているが、より数値が大きい値となっている内部電位ほど、不応期の値が小さくなる傾向が見られる。これは、スパイク発火が起き、その後の発火を抑制する働きによるためである。

5 まとめ

本研究では、スパイクニューラルネットワークを利用して、教師信号を与えたエージェントの学習環境を構築した。

従来研究では、実際の高齢者を被検者として、物理的なセンサーによって観測、スパイクニューラルネットワークへの入力を行っていたが、

提案手法の環境では被検者をエージェントとして、センサー等も含めてコンピュータ上でシミュレーションを行ったため、行動の複雑性が実際の人間のものよりも小さくなってしまった。

また、各ニューロンの内部電位に、比較的大きめのばらつきが見られた。これは、ニューロン毎に設定した結合重み、閾値などの定数の差などによるものと考えられる。

さらに、内部電位の大きさに反比例してそこに対応する不応期は小さくなることが期待されたが、一部では、その傾向が見られない部分も存在した。

今後の課題として、学習されるパターンをより複雑化すること、各内部電位のばらつきを抑えること、不応期と内部電位の対応関係を見直す事などが上げられる。

また、減衰率、閾値や結合重みなどそれぞれの定数を変更し、引き続き実験を行う。

「参考文献」

- 1) 大保武慶,久保田直行,“階層型スパイクニューラルネットワークを用いた行動推定のためのオンライン学習”,日本知能情報ファジィ学会誌,vol24,No.1,pp592-600,(2012)