

時系列データに内在する文脈構造を動作探索に用いる学習機械

Learning machine that uses context structure to search policy

柳川 誠介 *

Seisuke Yanagawa*

オプティッド

OptiD

*E-mail: s_yanagawa@jcom.home.ne.jp

Abstract: A system that transits from the initial state to the target state is assumed. The process of state transition is represented by time series data. The time series data is not given to the system unlike a program of a computer, but acquired by trial and error.

To combine and search time series data, the context structure inherent in time series data is used. For example, even if the details of the time series data leading to the target state at the time of searching can not be determined, the time series data immediately before reaching the target state and the time series data indicating the movement from the initial state are linked at the upper level of the context. In other words, if there is an overlap in the tree structure, it becomes a search candidate. It has been announced that the hierarchical structure is inherent in the time series data and that the basic sequence making up the time series data can naturally correspond to the activation area in the neural network.

1 はじめに

人間が持つ鳥のように空を飛ぶたいという欲求は飛行機を生んだが、ジェット・エンジンやロケットエンジンへと発展すると飛行原理は鳥とはかけ離れたものになる。数を数えやすくするために考案された算盤の操作は思考過程を逐次反映しているが、演算処理手順を内蔵したコンピュータは単純に算盤の発展型と見なしてよいだろうか。同様に、現在の人工知能研究の根幹にあるニューラルネットワークにバックプロパゲーションを用いた手法の延長には汎用人工知能の実現があるのだろうか。目標実現への道程は複数あろう。たとえすぐに商業的な応用は期待できなくても知能とは何かを基礎から考えることは大切であろう。

動物の最も基本的な行動は食物を手に入れ消化器官へ移動させることである。進化の始まりに位置する動物の多くはこの摂食行動の繰り返しが行動のほとんどを占める。進化により学習能力を得た動物は、摂食行動の前にどのような状況にあったかが記憶し

ていて、記憶されていた状況と現実の状況とを比較し、新たな摂食行動を起こすか否かの判断に役立てる。判断を下そうとしている時点を中心とする時系列データを考察してみよう。

ある程度進化した動物ならば複数の手順を実行後に目標に到達するような行動も取り得る。ひとつの手順を完了する毎に次に行くべき行動が明確になっていく。目標への到達過程は遠景が近付くと共に詳細が判明していく様に例えられようか。その一方、終了し処理は過去のものとして細部は徐々に失われ、時系列の中でどのような文脈にあるかが残り、やがてその存在も新たなデータの中に埋もれていく。すなわち、時系列データのうち最も密接にシステムと関わるのは「現在」であり、その前後すなわち「過去」と「未来」は「現在」から遠ざかるにつれシステムとの関わりが疎になり詳細から文脈へと失われていく。かような性質を持った時系列データの流れを我々の「意識」なるものになぞらえることはそう無理でもなかろう。

2 提案方法

有限長のテープ上の記号をヘッドで読み書きしながら移動するチューリング・マシン (図 2.1) を考える。状態機械 M は左の初期状態からテープ上の記号を読み書きしながら移動する。 M はごく単純な機能を持つ素子の結合から成り、 M の状態は活性化している素子の分布に対応していて、分布の変化は右の目標状態へ引きつけられるようになっていく。


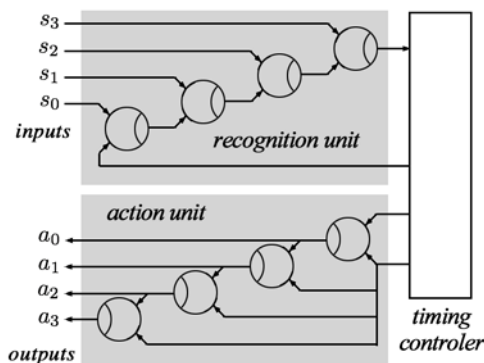


図 2.1 提案するシステムの論理的表現

変化の様相は M の入出力および状態遷移の動きに内在する文脈構造に依存する。初期状態から目標状態への遷移に何度か成功すると遷移は学習され初期状態に引き続く入出力の予測を M のより効率的な動作に生かすことができる。

図 2.2 は M を構成する素子の例で AND 素子に準ずる論理素子で機能を示す。長さ 4 の $s_0s_1s_2s_3$ なる入力刺激に対して長さ 4 なる作用の時系列 $a_0a_1a_2a_3$ を返す。入力の中から $s_0s_1s_2s_3$ に反応する部分を認識ユニット、作用 $a_0a_1a_2a_3$ を生成する部分を作用ユニットと呼ぶことにする。



Two elemental units constituting the learning machine

図 2.2 認識ユニットと作用ユニット

図 2.2 の例の持つ機能は単細胞生物など原始的動物の環境に対する反応に近い。原始的動物は生存に必要なものを求めて行動し、危険があれば回避する。原始的動物の動作は標準ロジック素子を基本にした電子回路などで容易に実現できる機能であり、知られている神経回路の知見の蓄積に沿った機能の組み合わせでシミュレート可能だろう。


次節以降で M の入出力の時系列それぞれが M 内の特定の素子の集合に対応できることを示し、素子の集合を階層的に構築することで入出力の対象を一般の時系列データに広げる。 M における問題可決とは、初期状態が目標状態へ変化するための時系列データを探索することであり、時系列データに内在する文脈構造が探索に役立つことを示す。

さらなる M の機能の拡張に際しては要素となる素子の機能はそのままにし、新たな機能を付け加えるにしても当面の課題を解決するための恣意的・不連続的な改変を避けたい。動物の脳の進化において神経細胞の結合状態は多様に複雑化したが、原始的動物でも知能を持った動物でも脳内の神経細胞の機能は変わらないという見解となじむようにしたい。要するに、できるだけ単純な機能の素子の組み合わせでどこまで包括的かつ汎用な機能を実現できるかを探り、その結果を脳の機能と照らし合わせ素子の機能を再検討するという道筋がよいと思われる。

脳のどこをとっても神経細胞の基本的機能は同じであるとしても、脳には海馬、小脳、視床、... と振る舞いが異なるいくつもの部分があるが、それらの機能もまた状態機械 M を構成する部品の機能と考える。 M を機能別に分割した方が効率的ならば分割し、分割されたある部分が脳のある部分の機能と類似していることが示されたら、それなりの成果と言えるだろう。

2.1 時系列データの文脈構造を素子の活性度の分布に対応させる。

時系列データを受けた学習機械において構成する素子の活性度がどのように変化するかを示すにあたって最も単純な例を図 2-3 で示す。



Sets of neuron accepting time-series datas

図 2.3 時系列データ $a_0 a_1 a_2 a_3$ を受取る素子

先頭の要素 a_0 を受信したとき、まず入力 a_0 に接続された素子が活性化される。続いて a_1 が受信されれば入力 a_1 に接続された素子が活性化されるが、活性度が高く主導権を持つのはすでに入力 a_0 で活性化された素子の集合に含まれていて、かつ入力 a_1 にも接続された集合であろう。 a_2 以降の要素に対しても同様である。かくして、先頭の要素 a_0 の受信に始まり活性化される素子の集合がデータ列が延びるに従い特定されていく。この過程は図 2-2 で示した認識ユニットで実現できる。

ただし、図 2.2 で扱う時系列データは系列中に同じ要素が複数回現れないことが前提で、一般の時系列データを扱うには時系列データを同じ要素が複数回現れない複数の部分列に分割する必要がある。簡単のため時系列データの要素を a_0 から a_9 までの 10 個とする。図 2.3 に示した例は要素をランダムに選んで配置した時系列データ (1) が 5 個の部分列 (2) に切り分けられることを示している。

切り分けは次のような手順で行う。

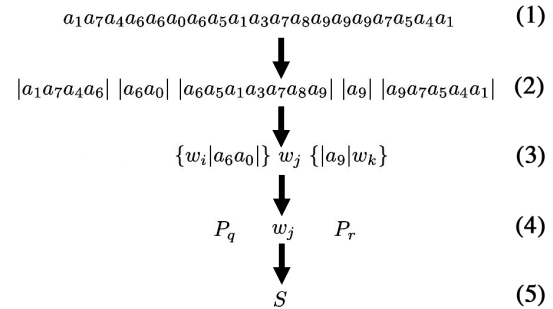
(1) 先頭の要素を最初の部分列の先頭とする。

与えられた例では先頭の要素は a_1 であり、続いて a_7, a_4, a_6 と部分列に付け加えていく。さらに、次の条件が成り立つとき部分列の末尾と見なし、新たな部分列の切り分けに移る。

(2) 延伸中の部分列にすでに含まれている要素と同じ要素が表れたら、部分列への付け加えは行わず、

新たな部分列の先頭の要素とする。この例では a_6 がその対象となる。


(3) 部分列に最大長が定められている場合、最大長に達した部分列の後に新たな部分列が設けられ、以後のデータが新たな部分列に付け加えられる。以上の手順により分割された部分列を基本列と呼ぶことにする。



Any time-series datas has hierarchic structure

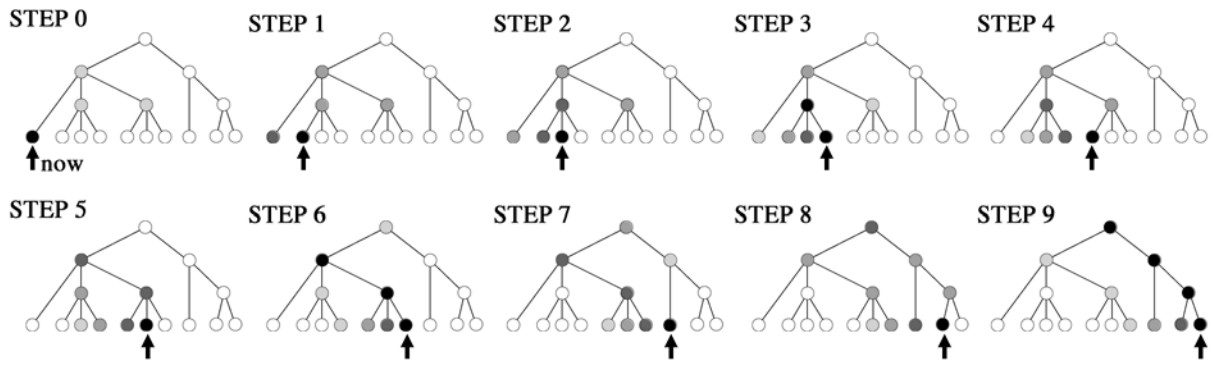
図 2.4 時系列データは基本列に分割できる

基本列は前述の方法により一般の時系列データを分割して得られたものであるゆえ、一般の時系列データは基本列の階層接続、すなわち基本列を新たな時系列データの要素と見なすことで処理できる。図 2.5 に処理系の構造を概念的に示す。



Structure of the suggesting Neural Network

図 2.5 一般の時系列データの処理系の概念図



Transition of activation areas according to the context of time series data

図 2.6 時系列データの文脈に従った活性化領域の遷移

2.2 文脈構造から活性化領域の状態遷移を予測する

前節で文脈構造が階層接続された認識ユニットおよび作用ユニットの結合の様相に対応できることを示した。図 2.6 は文脈構造を持った時系列データを受理あるいは時系列データに基づいた出力動作を行ったときの活性化される領域の変遷の例である。認識ユニットおよび作用ユニットはまとめて時系列データを認識・生成をする双方向の機能を持った領域とし、以下単にユニットと呼ぶことにする。


視覚化を容易にするためユニットの状態を 0, 1, 2, 3 とし、不活性化状態 0 を示す白から最大活性度 3 を示す黒までの 4 種の濃淡で示す。図中矢印で示したのは入力中あるいは出力中のユニットで活性度 3 である。つまり、この矢印より右が未来、左が過去となる。ユニットの状態遷移の骨子は次の通り。

- (1) 活性度 0 のユニットは結合しているユニットが活性度 3 になると活性度は 1 になる。
- (2) 活性度 1 になったユニットは下位に結合しているユニットを活性化し、自身の活性度は 2 になる。
- (3) (2) で活性化された下位のユニットがすべて活性化されたら自身の活性度は 3 になり、結合されている上位のユニットの活性度を上げる。
- (4) 新たな活性化の要因がないユニットは時間と共に活性度が下がっていく。つまり、活性化の過去の動きは消されていく。

状態遷移の過程で注目すべきはユニットの状態変化が変化の発生源から上位の層にあるユニットを活

性化し、活性化の結果が下位の層にあるユニットの活性化を促していることである。その結果、次の時間ステップで活性化されるべきユニットが何ステップか早く活性化されることが起こりうる。早めに活性化されたユニットの意味することは、時系列データの入力の場合は予測、時系列データの生成の場合行動に対する「構え」と例えてもよいだろう。さらに日常的な言葉で言えば、「**何が起ころうと長い目で見ればそれはある物語のひとコマ**」と言えようか。

ユニットの層内の動作は上の層から見ればコンピュータ・プログラムにおけるサブルーチンに相当する。図 2.6 においてはサブルーチンは 3 回（うち 2 回は同一であってもよい）コールされている状況に対応する。もし、サブルーチンをコールする手順がない、あるいは（忘却などで）弱まった場合は層間の結合を探索し、試行錯誤の結果成功した結合があれば学習結果として結合をより強化していけばよい。すなわちパーセプトロンによる図形の学習と同様にアルゴリズムを学習することである。



Even if connections between units weaken, they become search targets

図 2.7 欠落した結合を探索して得る

3 むすび

学習機械を同一機能の素子の結合体と考え、できるだけ単純な機能の素子の組み合わせでどこまで包括的かつ汎用な機能を実現できるかを時系列データの処理について考察した。学習機械における問題解決アルゴリズムの発見や学習は人工知能への最終目標のひとつであろう。

本稿で至らなかったのは文脈構造を持った時系列データの処理における素子の状態遷移を定式化すると共に学習および探索を明快な演算方法で記述することである。例として図3は学習機械において活性化されている初期状態と目標状態の二つの領域を示している。いくつかの状態遷移を経て初期状態が目標状態に吸収されて行く様が数式と図形の両面で表現できるようにしたい。




図3 初期状態および目標状態が活性化された学習機械

また、アルゴリズムと図形との橋渡しとしてグラフ理論や位相幾何などの現代数学が開いた成果を取り入れることができれば展望はさらに広がることだろう。

ハードウェア化に関しては、提案した学習機械の基本素子は入出力のそれぞれとは分散化された状態で接続されている。つまり、1ビットの誤りもなく接続されていなければ動作しないコンピュータとは異なり、確率的・アナログ的に動作する部分を持っていて、学習により動作の正確さを上げることができる。もし、故障などの原因である処理をつかさどる部分が失われたとしても、他の部分が同じ処理を行えるよう学習すればよい。実際の脳の故障や劣化を補償する機能に近い動作が期待できる。

参考文献

- [1] 柳川誠介, 時系列データを階層的に送受信するニューラルネットワーク, 人工知能学会研究会資料 SIG-AGI-003-02
- [2] 柳川誠介, 時系列データを学習・生成する階層的ニューラルネットワーク, 人工知能学会研究会資料 SIG-AGI-005-01