

## 時系列パターンを持つ運動物体の移動予測に関する基礎研究

6 E - 6

○鈴木直大 嘉数侑昇

北大工学部

## 1. はじめに

ロボット工学や生産システムの分野において、様々な運動物体の移動予測を自律的に行うことが求められており、そのための適応的かつ柔軟な処理方式が必要とされている。

このような目的のもとでの動画処理は従来主にオプティカルフローなどの解析的な手法で処理されてきているが、これに対し、この運動物体の軌跡という時系列データをパターンとして考え、ニューラルネットワークを用いて処理することが注目されている。

ここで用いるリカレントニューラルネットワークは、非階層・回帰結合を持つため、現在の入力値と、過去の影響を保存する内部状態から出力値が計算され、時系列データを直接処理することが可能である。

本研究では、扱う時系列パターンとその認識および予測を定義し、一次元上での点の運動に対するネットワークモデルの構造を定め、運動点の予測を行う。そして、これを用いて2次元上の運動点の移動予測を行う。

## 2. 時系列パターンの定義

ここでは時系列パターンおよびその認識・予測を以下のように定義する。

## 2.1 時系列パターン

ここでは物体を質点系と考える。この物体の運動の軌跡は空間軸と時間軸を持ち、一次元上での点の運動を考えると  $x(t)$  で表現される。これがパターンを持つとは、 $x(t)$  が周期性を持つことであり、すなわち運動の時系列パターンとは、

$$|x(t) - x(t+nT)| < \epsilon \quad (1)$$

$$(0 < \epsilon \in R, n = 1, 2, \dots)$$

を満足することとする。ここで  $T$  は周期である。

## 2.2 認識

パターンを  $x(t)$  として、認識システムの出力を  $x'$  としたとき、

$$|x(t) - x'(t+nT)| < \epsilon \quad (2)$$

$$\text{where } (\exists t_s < t < \infty)$$

が成り立つ。ただし  $\inf t_s = \hat{t}_s$  は、パターンの認識に対して、システムが安定状態に入った時刻である。

## 2.3 予測

$x(t)(t < t_0, T < t_0)$  に対し、 $x'(t)(\hat{t}_s < t_0 < t)$  が得られ

たとき、以下の式が成り立つ。

$$|x'(t) - x'(t+nT)| < \epsilon' \quad (3)$$

$$\text{where } (\hat{t}_s < (t-nT))$$

## 3. 時系列パターンの認識のためのネットワーク

## 3.1 ネットワークモデルの構造

一次元のフィールドは点(画素)の集合とする。そしてこの点上を質点が移動して行くものとする。このとき時刻  $t$  でのシステムへの入力  $TP$  は、

$$TP(t) = \langle P_1(t), P_2(t), \dots, P_n(t) \rangle$$

$$(0 \leq t \leq \infty) \quad (4)$$

と書ける。ただし、 $P_i(t) \in \{0, 1\}$ ,  $\sum P_i(t) = 1$  である。これに対するリカレントニューラルネットワークを Fig.1 のように構成する。

入力層ユニットを  $N_1$  個持ち各ユニットは入力セクタとして機能する。中間層ユニット、出力層ユニットはそれぞれ  $N_2$  個、1 個とし、これらのユニットはシグモイド関数を出力関数としている連続時間モデルである。また、中間層は層内相互結合を持ち、初期状態ではランダムな結合荷重により結合されている。ただし自己ループは持たないものとする。

ネットワークには learning mode, unlearning mode, performance mode があり、各ダイナミクスは、以下の通りである。

$$y_{1i}(t) = \begin{cases} P_i(t) & (\text{learning, unlearning mode}) \\ f_i(y_{31}(t)) & (\text{performance mode}) \end{cases} \quad (5)$$

$$\text{where } f_i(x) = \begin{cases} 1, & \text{if } l_i \leq x \leq u_i \\ 0, & \text{if otherwise.} \end{cases}$$

$$\tau \frac{d}{dt} x_{2i}(t) = -x_{2i}(t) + \sum_{j=1}^2 \sum_{k=1}^{N_j} w_{(2i)(jk)} y_{jk}(t) \quad (6)$$

$$\tau \frac{d}{dt} x_{31}(t) = -x_{31}(t) + \sum_{i=1}^{N_2} w_{(31)(2i)} y_{2i}(t) \quad (7)$$

ここで  $y_{2i}(t) = g(x_{2i}(t))$ ,  $y_{31}(t) = g(x_{31}(t))$  であり、 $g(x) = (1 - e^{-x}) / (1 + e^{-x})$  である。また、 $x_{ij}$  :  $i$  層 (1:入力層, 2:中間層, 3:出力層)  $j$  番目のユニットの内部状態値、 $y_{ij}$  : 出力値、

A study on the prediction of moving objects along with sequential patterns

Naohiro SUZUKI, Yukinori KAKAZU

HOKKAIDO University




Fig.1 The structure of the network.

$w_{(ij)(kt)}$ :  $k$ 層  $i$ ユニットから  $j$ ユニットへの結合荷重,  $\tau$ : 中間・出力層ユニットの状態値の減衰時定数,  $l_i, u_i$ : 入力ユニットの受容域の上・下限である.

learning modeは教師入力パターンに対し学習を行う. un-learning modeは、入力パターンが提示されるが学習は行わず、パターンの識別を行う. そして performance modeは、ネットワークの出力を入力することにより次の出力を得、これを繰り返すことにより予測を行うものとする.

3.2 ネットワークの学習

ここで用いる学習は、銅谷ら [DO89] による continuous-time back-propagation 法をベースとし、そこで用いられているネットワークを拡張した以下の式に従って行う.

教師信号を  $d(t) = f(\langle P_1(t), P_2(t), \dots, P_n(t) \rangle)$ , エラー関数は  $E(t) = \frac{1}{2}(y_{31}(t) - d(t))^2$  として,

$$\frac{d}{dt}w_{(31)(2i)}(t) = -\eta(y_{31} - d(t))Y_{31}T w_{(31)(2i)} \quad (8)$$

$$\frac{d}{dt}w_{(2i)(jk)}(t) = -\eta(y_{31} - d(t))Y_{31}T w_{(2i)(jk)}Y_{2i}T y_{jk}(t) \quad (9)$$

とする. ここで  $Y_{31} = (1 - y_{31}(t)^2)/2$ ,  $Y_{2i} = (1 - y_{2i}(t)^2)/2$ ,  $T = (1 + \tau d/dt)^{-1}$  であり,  $\eta$ は学習係数である.

4. 二次元上の運動の予測

二次元フィールドを画素の格子配列と考え、二直交軸方向へ射影したものを、二つの Fig.1 のネットワークへの入力とする. そしてこれらの出力を再び直交座標上に再構成することにより二次元上の運動を表現し、予測することとする (Fig.2).




Fig.2 The model of two-dimensional patterns.

5. シミュレーション

5.1 一次元上の運動

まずネットワーク単体の挙動を調べる. 例として Fig.3 に鋸波を入力した時の performance modeを示す. このように急激に運動方向が変化する場合は多少まるめてしまっているが、ほぼ予測できているといえるであろう.

5.2 二次元上の運動

二つのパターンに対する performance modeの結果を Fig.4, Fig.5 に示す. Fig.4 は矩形運動であり, Fig.5 は 8 の字運動である. Fig.4 は 5.1 の時と同様角のまるめが見られ, Fig.5 も軌道のズレが見られるが、ほぼ予測可能といえる.

しかし二つのネットワークそれぞれがかなり正確に学習されないと、二次元の場合は軌跡のズレが大きくなりがちであり、この問題点の改善が今後の課題である.

6. おわりに

時系列パターンとその認識および予測を定義し、一次元上での点の運動に対するネットワークモデルの構造を定め、運動点の予測を行った. そして、これを用いて二次元上の運動点の移動予測を行った.




Fig.3




Fig.4




Fig.5

参考文献

[DO89] Doya, K., Yoshizawa, S.: "Adaptive Neural Oscillator Using Continuous-Time Back-Propagation Learning," Neural Networks, Vol.2, No.5, pp.375-385(1989).