

北大工 ○鈴木直大 嘉数佑昇

要 旨

物体の運動などを考えた場合、その認識や移動の予測をする事は重要なことである。そこでこれらの時系列データを処理するための一手法として、時系列データを動的パターンとして扱い、それを直接処理できるリカレントニューラルネットワークを用いることとする。そしてそのためのネットワークモデルの構造を定め、このモデルの性質を探り、動的パターンの認識・予測の可能性を検討する。

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は、物体の運動を認識・予測することなどの、時系列データを扱う動画像処理問題が重要であり、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た。

これに対し、この時系列データを動的パターンとして考え、リカレント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。このネットワークは、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、動的パターン、およびその認識・予測について定義する。そして、銅谷ら [DO89] の Adaptive Neural Oscillator を拡張することにより、一次元上での点の運動という問題に対するニューラルネットワークモデルの構造を定め、その挙動から動的パターンの認識・予測の可能性を検討する。

2.動的パターンの認識・予測

初めにここで言う動的パターンおよびその認識・予測について定義する。

2.1 動的パターン

ここでは物体を質点系と考える。一般に物体の運動の軌跡等は空間軸と時間軸を持ち、 $x(t)$ 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、すなわち動的パターンとは、

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

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

を満足することとする。ここで T は周期である。

2.2 認識

動的パターンを $x(t)$ として、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、動的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.動的パターン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

動的パターンは有限な一次元上の点の移動であるので、システムへの入力を考慮し、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、

$$TP(t) = \langle P_1(t), P_2(t), \dots, P_n(t) \rangle \quad (0 \leq t \leq \infty) \quad (4)$$

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。

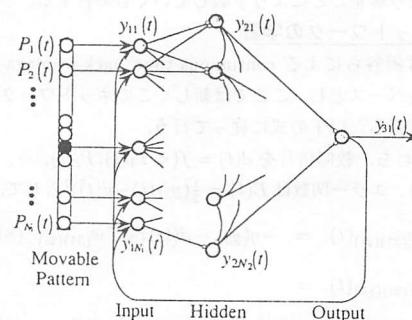


Fig.1 The structure of the network.

入力層ユニットを N_1 個持ち各ユニットは入力セレ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

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、初期状態として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、そのダイナミクスは、以下の通りである。

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

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

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

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

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、 $w_{(ij)(kl)}$: k 層 l ユニットから i 層 j ユニットへの結合荷重、 τ : 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 では教師入力パターンに対し学習が行われる。unlearning mode では、入力パターンが提示されるが、学習は行われない。これはパターンの識別を行う為である。そして performance mode では、ネットワークの出力が入力されることにより次の出力が得られ、これを繰り返すことにより予測していくものとする。

3.2 ネットワークの学習

学習は鈴谷らによる continuous-time back-propagation 法をベースとし、ここでは新しくこのネットワークに対し拡張した以下の式に従って行う。

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

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

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

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、 η は学習係数である。

4. シミュレーション

次にいくつかの動的パターンを与える、それに対するモ

デルの挙動を求め、認識・予測の可能性について調べる。

Fig.2~Fig.4 はそれぞれ、正弦波 (Fig2)、矩形波 (Fig.3)、正弦波+ホワイトノイズ (Fig.4) のパターンを与えたときの performance mode の挙動を示している ($N_1 = 20, N_2 = 8$ 、実線:入力、破線:TP)。

Fig.2 のように学習が完了した場合はパターンを忠実に再現しており、認識・予測可能である。また、unlearning mode では、学習したパターンと同じパターンの入力にはそのパターンを出力し、異なる場合は異なる出力をするので識別可能となる。

Fig.3 の様に変化が急激な場合は、まるで認識できているがほぼ認識できており、予測可能といえるであろう。

Fig.4 の場合はほぼ内挿している。このようにパターンに対し変動が局所的な場合、補間し、大局的なパターンのみを記憶して、それを認識・予測することが可能であるといえる。しかし逆に、大局的なパターンを追ってしまうため、パターン内の高周波成分の異なる様なパターンの識別は不可能であり、今後の課題となっている。

また、このネットワークモデルを x 軸方向・ y 軸方向それぞれに用いれば、それらのリサーチュをとることにより、二次元の動的パターンも認識・予測が可能であろう。

5. おわりに

一次元上の点の運動という問題のためのネットワークの構造を定め、その挙動を調べることから動的パターンの認識・予測への可能性を検討した。

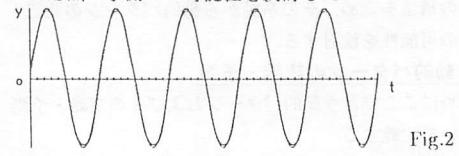


Fig.2

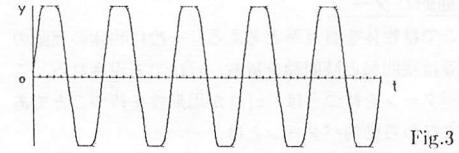


Fig.3

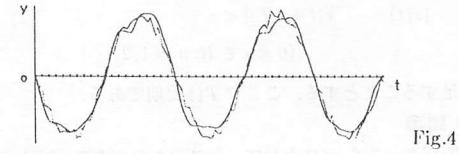


Fig.4

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).